POLITECHNIKA RZESZOWSKA
im. IGNACEGO ŁUKASIEWICZA

WYDZIAŁ BUDOWY MASZYN I LOTNICTWA
POLITECHNIKI RZESZOWSKIEJ

Opracowanie i wdrożenie metody hybrydowej inspekcji optycznej zgrzewanych termicznie opakowań z tworzyw sztucznych

Autor: mgr inż. Piotr Garbacz

Promotor: prof. dr hab. inż. Andrzej Burghardt

Promotor pomocniczy: dr hab. inż. Magdalena Muszyńska, prof. PRz

Rzeszów 2026

Składam serdeczne podziękowania:
promotorowi ***prof. dr hab. inż. Andrzejowi Burghardtowi***
oraz promotorowi pomocniczemu ***dr hab. inż. Magdalenie Muszyńskiej, prof. uczelni***
za życzliwość, opiekę naukową oraz nieocenioną pomoc podczas realizacji pracy.

.

Najszczersze podziękowania chciałbym złożyć mojej rodzinie.
Synowi ***Filipowi*** *dziękuję za cierpliwość i wyrozumiałość w trakcie pisania rozprawy.*
Szczególne wyrazy wdzięczności kieruję do mojej żony, ***Sylwii****, której wsparcie,*
motywacja i pomoc były dla mnie nieocenione na każdym etapie tej drogi.

Spis treści

1. Wprowadzenie 7

1.1. Motywacja 8
1.2. Geneza problemu 9

2. Przegląd stanu wiedzy 11

2.1. Zjawiska fizykalne w systemach wizyjnej inspekcji 16
2.2. Rodzaje i klasyfikacje metod inspekcji optycznej 22
2.3. Metody fuzji obrazów 37
2.4. Metody inspekcji optycznej opakowań zgrzewanych termicznie 39

3. Cel i zakres pracy 45

4. Metoda hybrydowej optycznej inspekcji opakowań 47

4.1. Opracowanie koncepcji rozwiązania 48
4.2. Modelowanie układów obrazowania 51
4.3. Stanowisko badawcze 70
4.4. Metoda kalibracji i rejestracji obrazów 74
4.5. Metoda fuzji obrazów dla wysokowydajnych systemów inspekcji 85
4.6. Algorytmy głębokiego uczenia detekcji i klasyfikacji defektów 87

Badania eksperymentalne 105

4.7. Zrobotyzowane stanowisko badawcze 107
4.8. Analiza danych z wykorzystaniem metod uczenia maszynowego 112

5. Wytworzenie i weryfikacja wersji prototypowej systemu 121

5.1. Implementacja hybrydowej metody inspekcji opakowań 121
5.2. Ewaluacja prototypowego systemu inspekcji 130

6. Podsumowanie 135

Bibliografia 139

1. Wprowadzenie

Kontrola jakości oraz diagnostyka techniczna urządzeń i maszyn są dynamicznie rozwijanym obszarem badań i prac inżynierskich w wielu gałęziach przemysłu. Wzrost konkurencji wynikający z globalizacji, a także regulacje obowiązujące w Unii Europejskiej zmuszają producentów do poszukiwania nowych rozwiązań umożliwiających redukcję kosztów oraz ograniczenie liczby odpadów [1]. Systemy zarządzania produkcją MES (*ang. Manufacturing Execution System*) wykorzystują dane procesowe, które pełnią kluczową rolę w dwóch obszarach: utrzymaniu ruchu maszyn oraz zapewnieniu standardów jakości [2]. Stanowi to impuls do nieustannego rozwijania metod, które umożliwiają osiągnięcie maksymalnej wydajności przy jednoczesnej redukcji zużycia surowców. Zgodnie z wprowadzoną na początku XX wieku koncepcją Jidoka [3], określaną też jako inteligentna automatyzacja, przyjęty został paradygmat poprawy wydajności poprzez mechanizmy ułatwiające identyfikację usterek na każdym etapie procesu produkcyjnego [4]. Rozwinięciem tego podejścia, była przedstawiona w 1980 roku przez dr Richarda J. Schonbergera, metodologia „produkcji klasy światowej" WCM (*ang. World Class Manufacturing*). Opierała ona swoje założenia na dążeniu do doskonałości w produkcji poprzez ciągłe odkrywanie i wdrażanie nowych technik oraz technologii pozwalających ograniczać straty [5]. W tym celu stosowane były statystyczna kontrola procesu oraz wizualna inspekcja każdego wyrobu. W nowoczesnym przemyśle rosnące znaczenie zyskuje 100% kontrola produkcji. Obecnie, dzięki postępującej cyfryzacji oraz możliwości zastosowania sztucznej inteligencji rozwijane są metody umożliwiające predykcję jakości wytwarzanych wyrobów [6]. W koncepcji jakości 4.0 (*ang. Quality 4.0*) [7] kluczowe znaczenie ma generowanie cyfrowych wątków danych dla każdego wytwarzanego produktu, obejmujących m.in. parametry procesu, atrybuty produktu oraz ilościową miarę lub wskaźniki jakości. Dane te mogą być wykorzystane do opracowania modelu cyfrowego bliźniaka (*ang. Digital Twin*), który umożliwia ciągłą optymalizację i doskonalenie procesu produkcyjnego [8]. Monitorując parametry maszyn oraz rezultaty inspekcji możliwe jest określenie zależności pomiędzy zmiennością procesu, a jakością produktów [9]. Ma to szczególne znaczenie teraz, kiedy jednym z głównych priorytetów producentów jest wprowadzenie założeń zrównoważonej produkcji w celu ograniczania odpadów i maksymalnego wykorzystania zasobów. Przykładem takich działań jest inicjatywa ZDZW (*ang. Zero Defect Zero Waste*) mająca na celu osiągnięcie poziomu zero defektów i zero odpadów w produkcji. Jej głównym założeniem jest wykorzystanie nieniszczących metod inspekcji. Poprzez wdrożenie zaawansowanych technologii obrazowania wraz z algorytmami sztucznej inteligencji możliwe jest usprawnienie procesów produkcyjnych, a kontrola jakości może obejmować całe partie wytwarzanych produktów, a nie jedynie ograniczone ilościowo próbki [10]. W tym kontekście podkreślane jest również znaczenie metod hybrydowych, łączących kilka technologii obrazowania w celu zwiększenia skuteczności i niezawodności systemów inspekcji [11].

1.1. Motywacja

Rozprawę doktorską zrealizowano w ramach programu „Doktorat wdrożeniowy”. Dotyczy tematyki zastosowania metod fuzji obrazów w przemysłowych systemach kontroli jakości opakowań. Jednostką współpracującą przy realizacji doktoratu była Sieć Badawcza Łukasiewicz – Instytut Technologii Eksploatacji, będąca uznanym producentem unikatowej aparatury badawczo–testowej na potrzeby zastosowań przemysłowych i naukowych. Prace badawcze prowadzone w Instytucie obejmują obszary zaawansowanych technologii, budowy i eksploatacji maszyn, inżynierii materiałowej, bezpieczeństwa technicznego i ochrony środowiska. W Centrum Mechatroniki i Prototypowania od kilkunastu lat realizowane były projekty ukierunkowane na zastosowanie zaawansowanych metod obrazowania i systemów kontroli jakości, które znalazły odbiorców w branży motoryzacyjnej, tytoniowej i szklarskiej. Utworzony w Instytucie Ośrodek Inteligentnych Specjalizacji, umożliwia realizację prac B+R szczególnie w zakresie systemów automatyzacji i robotyzacji procesów produkcji z wykorzystaniem technologii optomechatronicznych.

Główną inspiracją do podjęcia tematyki była potrzeba opracowania zaawansowanych systemów inspekcji optycznej wykorzystujących połączone metody obrazowania, które umożliwiałyby wieloparametryczną kontrolę wyrobów w procesach wytwarzania oraz monitorowanie procesów technologicznych. Współczesna automatyzacja produkcji coraz częściej ukierunkowana jest na przewidywanie potencjalnych odchyleń procesowych jeszcze przed pojawieniem się jakichkolwiek anomalii. Metody hybrydowe stanowią nowy kierunek badań w obszarze przemysłowych systemów wizyjnych. Przewiduje się, że w połączeniu z metodami sztucznej inteligencji umożliwią one autonomiczną optymalizację procesów [12].

Rynek opakowań zgrzewanych termicznie to dynamicznie rozwijający się sektor, z rosnącym popytem na innowacyjne rozwiązania, obejmujące również wykorzystanie materiałów biodegradowalnych. Funkcje opakowania obejmują: ochronę produktu przed czynnikami zewnętrznymi, umożliwienie jego bezpiecznego transportu oraz zachowanie stabilności w trakcie przechowywania. Kluczowym elementem determinującym skuteczność tych funkcji jest szczelność i trwałość zgrzewu, który odpowiada za barierowość wobec wilgoci, gazów i mikroorganizmów, a tym samym ogranicza straty jakościowe oraz zapobiega powstawaniu odpadów żywnościowych. Zapewnienie stabilnych i optymalnych warunków w procesach pakowania jest problematyczne, głównie ze względu na rosnące tempo produkcji, konieczność redukcji kosztów poprzez modyfikacje materiałowe, a także dążenie do skrócenia czasów operacyjnych i obniżenia zużycia energii. W tym kontekście wady uszczelnień oraz potrzeba pełnej kontroli jakości stanowią istotne wyzwania technologiczne. Aktualnie w Polsce można zaobserwować wzrost zapotrzebowania na kompleksowe systemy przeznaczone do produkcji dań gotowych i o wydłużonym okresie przydatności. Według ekspertów wartość tego rynku będzie wzrastać średnio o 7% rocznie [13]. Zwiększenie wolumenu produkcji musi następować z zachowaniem wymaganego poziomu jakości wytwarzanych produktów. Kontrola opakowań jest krytycznym etapem procesu produkcyjnego, uwzględnianym w audytach HACCP (*ang. Hazard Analysis and Critical Control Point*), mającym na celu zagwarantowanie

integralności produktów opuszczających zakłady produkcyjne. Ma to szczególne znaczenie w przypadku przemysłu spożywczego i potencjalnych odpadów pochodzenia zwierzęcego, które cechują się dużym śladem węglowym. Na podstawie analizy rynku stwierdzono potrzebę rozwoju systemów kontroli jakości opakowań, które minimalizują ryzyko strat finansowych producentów, związanych z utratą wiarygodności, koniecznością utylizacji lub przepakowania wadliwych wyrobów.

Główną motywacją podjęcia tematyki badawczej było opracowanie autorskiego rozwiązania, które będzie stanowić nową ofertę produktową Łukasiewicz-ITeE, wytwarzaną seryjnie na potrzeby branży spożywczej. Zastosowanie opracowanego rozwiązania przez polskich producentów zwiększy ich konkurencyjność i umożliwi eksport wysokiej jakości wyrobów spożywczych.

1.2. Geneza problemu

W ramach podjętej współpracy Łukasiewicz–ITeE zawarł umowę z wiodącym przedsiębiorstwem z sektora spożywczego, które wyraziło zainteresowanie rozwojem zaawansowanych systemów inspekcji opakowań wykorzystywanych w procesach produkcyjnych. Pilotażowe wdrożenie systemu inspekcji zaplanowano na linii pakującej, w jednym z najnowocześniejszych zakładów drobiarskich w Polsce. W związku z wprowadzoną przez przedsiębiorstwo automatyzacją procesu produkcyjnego, obejmującą etap umieszczania gotowych wyrobów drobiowych w opakowaniach, podjęto decyzję o konieczności zastosowania na tym etapie zaawansowanego systemu kontroli jakości. Istotnym zagadnieniem dla przedsiębiorstwa stała się również możliwość analizy rodzajów defektów oraz identyfikacji zależności przyczynowo-skutkowych w procesie zgrzewania termicznego opakowań z tworzyw sztucznych.

Rozwój systemów obrazowania zapewnia coraz większą liczbę narzędzi możliwych do zastosowania w przemysłowych systemach inspekcji. Większość obecnie dostępnych komercyjnie rozwiązań, opiera swoje działanie na wykorzystaniu pojedynczych technik. Prowadzone są jednak prace nad systemami nowej generacji, które ukierunkowane są na zwiększenie poziomu automatyzacji, dokładności oraz niezawodności inspekcji. Jednym z głównych kierunków badań są metody wykorzystujące fuzję danych pochodzących z różnych sensorów [14]. Zalety hybrydowych systemów inspekcji wynikają z możliwości akwizycji rozszerzonych zbiorów danych o obiekcie, na podstawie informacji zakodowanych w poszczególnych obrazach rejestrowanych z wykorzystaniem różnego rodzaju sensorów. Umożliwia to uzyskanie redundancji i komplementarności informacji o wadach powstających podczas danego procesu produkcyjnego. Zastosowanie tego rodzaju układów wymaga jednak starannego doboru poszczególnych technik obrazowania, z uwzględnieniem ich specyfiki i ograniczeń [11]. Po uzyskaniu obrazów o odpowiedniej jakości należy następnie przeprowadzić operację fuzji, umożliwiającą skuteczną integrację informacji pochodzących z różnych źródeł. W literaturze liczne są przykłady wykorzystania metod fuzji obrazów

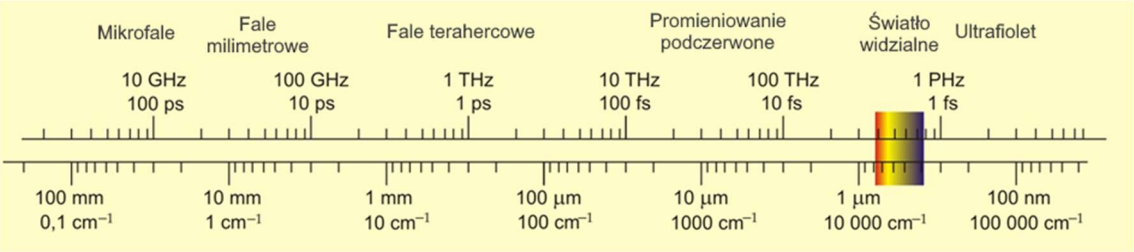
w obszarze medycyny oraz systemów bezpieczeństwa. Rozwiązania te nie uwzględniają jednak rygorystycznych wymagań występujących w środowisku przemysłowym. W większości przypadków celem obecnie wykorzystywanych metod fuzji jest poprawa jakości obrazów ukierunkowana jedynie na ich prawidłową interpretację przez operatora systemu, najczęściej bez uwzględnienia wydajności obliczeniowej zastosowanych algorytmów [15]. Głównym celem hybrydowych systemów inspekcji, przeznaczonych do zastosowań przemysłowych, jest prawidłowa ocena stanu obiektu na podstawie zarejestrowanych obrazów w ściśle określonym i ograniczonym czasie. Istotnym zagadnieniem podczas projektowania tego typu systemów jest dobór odpowiednich sensorów zapewniających obrazy o wysokiej jakości, który jest ściśle uwarunkowany specyfiką zastosowania danego systemu. Zależy on nie tylko od rodzaju materiału badanego elementu, lecz także od charakteru potencjalnych defektów, które należy wykryć lub sklasyfikować. Podczas projektowania hybrydowych systemów kontroli jakości, należy uwzględnić takie czynniki jak:

- charakterystykę zastosowanych sensorów oraz układów optycznych,
- metody oświetlenia strefy pomiarowej,
- ograniczenia mechaniczne,
- odporność układu na czynniki zakłócające.

Osiągnięcie założonego poziomu skuteczności i niezawodności systemu inspekcji zależy od właściwego doboru parametrów technicznych oraz funkcjonalnych zdeterminowanych poprzez wymienione czynniki. Pomimo dużego wzrostu, w ostatnich latach, liczby publikacji w obszarze metod fuzji obrazów [16], projektowanie układów obrazowania hybrydowej inspekcji optycznej w zastosowaniach przemysłowych pozostaje zagadnieniem otwartym [17]. W dysertacji zaproponowano metodę hybrydowej optycznej inspekcji zgrzewanych termicznie opakowań z tworzyw sztucznych. Istotą opracowanego rozwiązania jest wykorzystanie unikalnych właściwości fal wybranych pasm promieniowania elektromagnetycznego oraz fuzji obrazów dedykowanej dla wysokowydajnej inspekcji. Defekty występujące po procesie zgrzewania termicznego mogą mieć różne źródło pochodzenia takie jak: niewłaściwe parametry czasu i temperatury, zanieczyszczenie strefy zgrzewania, nieprawidłowe pozycjonowanie lub zużycie elementów grzewczych. Uzyskanie stabilnych i powtarzalnych warunków produkcyjnych pozostaje problematyczne, głównie z uwagi na rosnące tempo procesów przemysłowych, konieczność redukcji kosztów poprzez modyfikacje materiałowe, a także dążenie do skrócenia czasu operacyjnego i zmniejszenia energochłonności. Oryginalność podjętych badań polega na możliwości wykorzystania zaawansowanych technik obrazowania do klasyfikacji wad, a następnie zastosowania tych informacji w systemach eksperckich oraz przy syntezie algorytmu sterowania procesem produkcyjnym. Opisana metoda przyczyni się do rozwoju inteligentnych systemów produkcyjnych oraz zrozumienia zjawisk fizykalnych występujących w procesie wysokowydajnej inspekcji optycznej materiałów zgrzewanych termicznie, tym samym wpisuje się w dyscyplinę inżynieria mechaniczna.

2. Przegląd stanu wiedzy

Metody obrazowania właściwości fizycznych obiektów znajdują szerokie zastosowanie w badaniach naukowych, diagnostyce technicznej i kontroli jakości. W zależności od aplikacji, w procesie obrazowania wykorzystywane są różne rodzaje pola, fal lub strumieni cząstek, które w wyniku oddziaływania z obiektem badań ulegają modyfikacji rejestrowanej następnie przez odpowiednie sensory [18]. Duża liczba wykorzystywanych metod opiera swoje działanie na analizie interakcji promieniowania elektromagnetycznego z materią. Promieniowanie elektromagnetyczne EM (*ang. Electromagnetic*) jest formą energii uwalnianej i absorbowanej za pomocą naładowanych cząstek, posiadających specyficzne właściwości elektryczne i magnetyczne. Zakres długości fal odpowiadających promieniowaniu elektromagnetycznemu jest określany terminem spektrum elektromagnetycznego (Rys. 1).



Rys. 1 Spektrum promieniowania elektromagnetycznego [19]

Spektrum elektromagnetyczne podzielone zostało na obszary, w których promieniowanie charakteryzuje się specyficznymi właściwościami związanymi z generowaniem lub detekcją fali. Zakresy częstotliwości, które odznaczają się podobnymi cechami noszą nazwę pasm. Podzakresy danego pasma definiowane są natomiast jako segmenty [20]. Granice między kolejnymi pasmami spektrum elektromagnetycznego nie są ściśle określone. Stosowane są również różne konwencje w nazewnictwie poszczególnych segmentów danego pasma.

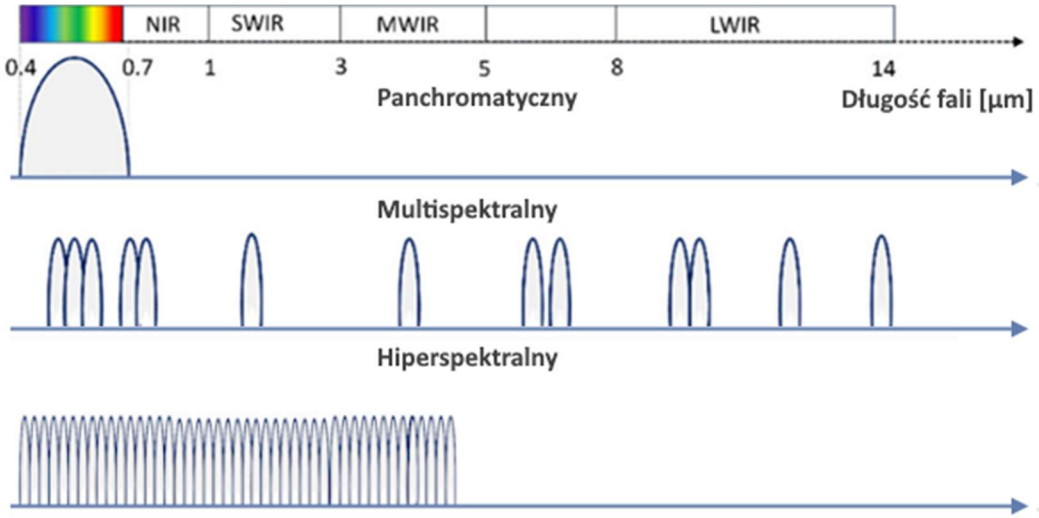
Sposób w jaki promieniowanie elektromagnetyczne oddziałuje na dowolny materiał może być wykorzystany do jego jakościowej lub ilościowej analizy [21]. W systemach diagnostyki i kontroli jakości najczęściej wykorzystywane jest promieniowanie widzialne opisywane również jako światło widzialne. Zakres spectrum elektromagnetycznego dla tego rodzaju promieniowania odpowiada w przybliżeniu przedziałowi czułości ludzkiego oka [22]. Z tego powodu inspekcją wizualną [23] określany jest proces polegający na ocenie badanego obiektu przez człowieka, bez wykorzystania dodatkowych narzędzi optycznych. Rozwinięciem tej metody są systemy inspekcji optycznej [24], w których w celu polepszenia jakości obrazu stosowane są różne układy optyczne, takie jak na przykład soczewki powiększające. Inspekcja optyczna może mieć charakter jakościowy, kiedy bazuje na subiektywnej ocenie operatora systemu lub ilościowy, kiedy za pomocą odpowiedniego sensora utworzony zostaje obraz, który następnie może zostać poddany analizie. Zakres spectrum elektromagnetycznego wykorzystywanego w systemach optycznej inspekcji nazywany jest promieniowaniem optycznym. Obszar ten znajduje się pomiędzy falami radiowymi oraz promieniowaniem

rentgenowskim X–ray, w zakresie długości fali od 10 nm do 1 mm [25]. W tym przedziale możliwe jest stosowane standardowych elementów optycznych, takich jak soczewki i zwierciadła, w celu manipulowania wiązką promieniowania. Ze względu na właściwości fizyczne zakres promieniowania optycznego może być podzielony w następujący sposób [26] [27] [28] :

- XUV (*ang. Extreme Ultraviolet*) – ekstremalne promieniowanie ultrafioletowe,
- FUV (*ang. Far Ultraviolet*) – promieniowanie ultrafioletowe dalekie,
- MUV (*ang. Middle Ultraviolet*) – promieniowanie ultrafioletowe środkowe,
- NUV (*ang. Near Ultraviolet*) – promieniowanie ultrafioletowe bliskie,
- VIS (*ang. Visible light*) – promieniowanie widzialne,
- NIR (*ang. Near Infrared*) – bliska podczerwień,
- SWIR (*ang. Short Wave Infrared*) – podczerwień krótkofalowa,
- MWIR (*ang. Middle Wave Infrared*) – podczerwień średniofalowa,
- LWIR (*ang. Long Wave Inrared*) – podczerwień długofalowa,
- VLWIR (*ang. Very Long Wave Infrared*) – bardzo daleka podczerwień,
- sub–THz – promieniowanie sub–terahercowe,
- THz – promieniowanie terahercowe.

Przez wiele lat obszar promieniowania optycznego nie był w pełni zbadany. Wynikało to z trudności w opracowaniu zarówno źródeł jak i detektorów zdolnych do operowania w zakresie częstotliwości od 1 do 10 THz. Często pasmo to określane było terminem luki terahercowej (*ang. terahertz gap*) [29]. Dopiero opracowane w ostatnich latach pierwsze kompaktowe źródła promieniowania oraz matryce wykorzystujące obszar promieniowania terahercowego, umożliwiły jego praktyczne zastosowanie w systemach inspekcji. Fale terahercowe, w przeciwieństwie do promieniowania rentgenowskiego, są niejonizujące i nie wymagają zaawansowanych zabezpieczeń. Charakteryzują się wyższą rozdzielczością przestrzenną obrazowania niż systemy mikrofalowe. Dodatkowo fale THz są czułe na wybrane substancje chemiczne i silnie absorbowane przez wodę, co umożliwia detekcję różnego rodzaju materiałów oraz analizę wilgotności. Poza rozwojem nowych detektorów i źródeł promieniowania istotnym obecnie zagadnieniem jest również automatyzacja procesów inspekcji. Urządzenia opracowywane w tym celu określane są terminami systemów automatycznej wizyjnej inspekcji AVI (*ang. automatic vision inspection*) lub zamiennie automatycznej optycznej inspekcji AOI (*ang. automated optical inspection*) [30]. W ich budowie wykorzystywane są matryce generujące obrazy, które są następnie za pomocą odpowiednich algorytmów przetwarzane i analizowane w celu pomiaru lub interpretacji obserwowanego obiektu. Obraz według normy ASTM E7–99, jest odwzorowaniem obiektu, które powstaje przez zastosowanie przyrządów optycznych takich jak soczewki lub zwierciadła. W ujęciu ogólnym definicja ta obejmuje obrazy postrzegane zarówno przez ludzki zmysł wzroku jak i rejestrowane przez sensory. Obrazami cyfrowymi określa się natomiast zbiory danych, które mogą być zarejestrowane i następnie przetworzone [31]. Klasyczne systemy wizyjne najczęściej wykorzystują obrazowanie panchromatyczne, w którym kamera

posiada pojedynczy sensor o wybranym zakresie spektralnym, rejestrujący intensywność uśrednionego sygnału. W obrazowaniu multispektralnym MSI (*ang. multispectral imaging*) wykorzystuje się również jeden tor wizyjny z pojedynczym sensorem o szerokim zakresie spektrum elektromagnetycznego [32], w którym zastosowany został dodatkowo specjalny mechaniczny lub przestrajalny układ filtrów [33]. Rozwiązanie takie umożliwia akwizycję obrazów tej samej sceny w kilku lub kilkunastu zakresach promieniowania elektromagnetycznego. Rozwinięciem tej metody są systemy wykorzystujące obrazowanie hiperspektralne HSI (*ang. hyperspectral imaging*) [34], które umożliwiają rejestrację kilkuset obrazów o różnym zakresie widma elektromagnetycznego. W tym celu konieczne jest zastosowanie specjalnych układów optycznych (pryzmatów lub holograficznych siatek dyfrakcyjnych) rozszczepiających promieniowanie elektromagnetyczne na powierzchni sensora na pożądaną liczbę wąskich zakresów. Na rysunku 2 przedstawione zostało porównanie systemów obrazowania spektralnego.



Rys. 2. Porównanie systemów obrazowania panchromatycznego, MSI i HSI [35]

Kamery hiperspektralne stanowią kompaktowe, zintegrowane układy, które generują sześcian hiperspektralny (*ang. hypercube*) na podstawie rejestrowanych obrazów w danym zakresie widma, utrzymując wspólny układ odniesienia dzięki rozwiązaniom sprzętowym i programowym producenta. Ograniczeniem tego typu systemów są trudności występujące w opracowaniu sensorów o dużej czułości oraz elementów optyki o wysokiej transmisyjności w szerokim zakresie promieniowania elektromagnetycznego.

Większość obecnie dostępnych komercyjnych rozwiązań wykorzystywanych w badaniach nieniszczących i kontroli jakości opiera swoje działanie na zastosowaniu pojedynczej techniki. Obrazowanie hybrydowe to technika łączenia różnych technologii detekcji promieniowania, której celem jest uzyskanie fuzji informacji w celu osiągnięcia na przykład zwiększonej skuteczności detekcji [36]. W literaturze często używa się zamiennie terminu obrazowanie multimodalne. Jednym z pierwszych znanych zastosowań była medycyna, gdzie wykorzystywano systemy łączące różne metody diagnostyczne, takie jak tomografia

komputerowa, rezonans magnetyczny czy promieniowanie rentgenowskie. Metody hybrydowe zwiększają prawdopodobieństwo detekcji określonych cech obiektu podlegającego inspekcji, a także umożliwiają uzyskanie efektu synergii w postaci nowych informacji niemożliwych do osiągnięcia za pomocą każdej z technik zastosowanej osobno. W celu zaprezentowania spektrum zastosowań i możliwych konfiguracji, w tabeli 1 przedstawione zostały wybrane przykłady systemów hybrydowych wykorzystywanych w diagnostyce technicznej i kontroli jakości.

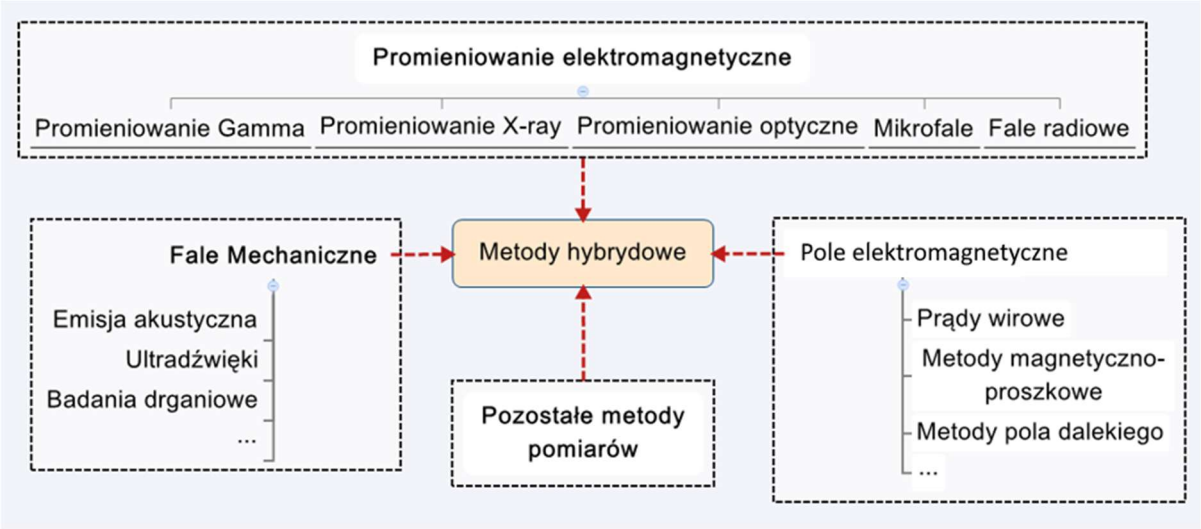
Tabela 1. Wybrane hybrydowe metody badań nieniszczących

Zastosowane technologie	Obiekt Badań	Osiągnięty cel
X–ray, Optyczna 3D [37]	Produkty spożywcze	Zwiększona skuteczność detekcji zanieczyszczeń/odpadów
Ultradźwięki, termografia, prądy wirowe [38]	Kompozyty CFRP PA66	Udoskonalona lokalizacja i klasyfikacja defektów
Promieniowanie X–ray, emisja akustyczna [39]	Wytwarzanie przyrostowe i spawy laserowe	Komplementarność metody i możliwość monitorowania w czasie rzeczywistym
Optyczna 3D, Hiperspektralna, X–ray [40]	Produkty spożywcze	Zwiększona skuteczność detekcji defektów
Optyczna, Podczerwień, X–ray [41]	Obrazy	Zwiększona dokładność detekcji pęknięć
Termografia, Prądy wirowe [42]	Kompozyty, ferromagnetyki	Komplementarność metody inspekcji dla różnych rodzajów materiałów
Prądy wirowe, Ultradźwięki, Mikrofale [43]	Spawy w konstrukcjach lotniczych	Zwiększona skuteczność detekcji korozji i pęknięć
Optyczna, termografia pasywna [44]	Płytki PCB	Komplementarność metody dla różnych rodzajów wad
Optyczna (3D i szerografia), termografia [45]	Kompozyty CFRP	Zwiększona skuteczność klasyfikacji defektów przy użyciu fuzji danych

Do najczęściej wymienianych zalet stosowania metod hybrydowych można zaliczyć:

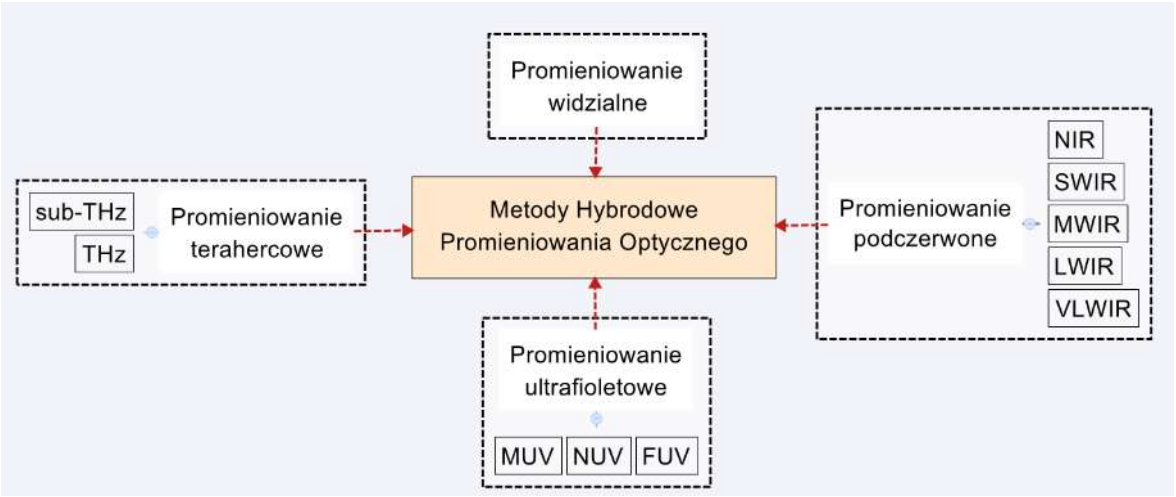
- zwiększoną skuteczność i niezawodność detekcji,
- udoskonaloną lokalizację i klasyfikację defektów,
- komplementarność metody w zakresie wykrywania różnych typów wad.

W ogólnym ujęciu systemy hybrydowe mogą łączyć w sobie zalety metod pomiarowych wykorzystujących różne zjawiska fizyczne takie jak promieniowanie przenikliwe, promieniowanie optyczne, fale akustyczne, pole elektromagnetyczne (Rys. 3).



Rys. 3. Hybrydowe metody inspekcji

Jednym z najczęściej wykorzystywanych w badaniach nieniszczących zjawisk fizycznych jest oddziaływanie promieniowania elektromagnetycznego z materią, które umożliwia badanie powierzchniowe, podpowierzchniowe oraz struktury obiektów. Spośród metod wykorzystujących różne zakresy spektrum elektromagnetycznego, szczególne znaczenie mają techniki obrazowania promieniowania optycznego. Wynika to między innymi z dużego rozwoju sensorów, układów optycznych a także metod przetwarzania i analizy obrazów. Ponadto techniki optyczne charakteryzują się dużą skalowalnością i możliwością rejestracji promieniowania zarówno w bliskiej jak i znacznej odległości od obiektu badań. Metody hybrydowe wykorzystujące zakres promieniowania optycznego (Rys. 4), dzięki unikalnym właściwościom fal elektromagnetycznych poszczególnych pasm, umożliwiają projektowanie systemów o zwiększonej skuteczności i niezawodności detekcji. Opracowanie i implementacja systemów hybrydowych wykorzystujących zakres promieniowania optycznego wymaga jednak interdyscyplinarnego podejścia, które uwzględniać będzie zjawiska fizykalne występujące w systemach wizyjnej inspekcji oraz metody fuzji i rejestracji obrazów.



Rys. 4. Metody hybrydowe promieniowania optycznego

Na podstawie przeprowadzonej analizy stanu wiedzy stwierdzono brak jednolitej metodyki projektowania i implementacji hybrydowych systemów wizyjnych. Jednocześnie literatura podkreśla znaczenie właściwego doboru metod obrazowania, które umożliwiają analizę przyczyn zmienności jakości kontrolowanych wyrobów [17].

2.1. Zjawiska fizykalne w systemach wizyjnej inspekcji

Wybór odpowiednich zakresów promieniowania optycznego, które zastosowane zostaną w systemie hybrydowym uwarunkowany jest wieloma czynnikami, które związane są między innymi z:

- obiektem badań (m.in. struktura, rodzaj materiału, właściwości fizyczne),
- wymaganiami pomiarowymi (m.in. częstotliwość pomiarów, rozdzielczość pomiarowa),
- cechami obiektu, które powinny być zidentyfikowane lub zmierzone (m.in. wymiary geometryczne, zmiany w strukturze, rozkład temperatury).

Zagwarantowanie wysokiej skuteczności i niezawodności hybrydowych systemów wizyjnych wymaga uwzględnienia zjawisk fizykalnych występujących podczas procesu inspekcji. Szczególne znaczenie ma sposób oddziaływania promieniowania elektromagnetycznego z materią w zależności od zastosowanej długości fali oraz zjawiska optyczne mające bezpośredni wpływ na dokładność pomiarów takich jak dyfrakcja, dystorsja, aberracja chromatyczna [46].

Promieniowanie elektromagnetyczne można opisać jako strumień fotonów, czyli cząstek poruszających się w sposób falowy z prędkością światła [47]. Falowy charakter promieniowania elektromagnetycznego charakteryzują następujące wielkości fizyczne: długość fali – λ [mm] i częstotliwość – ν [Hz]. Energia pojedynczego fotonu – E określona

przez prawo Plancka, wiąże się z podanymi uprzednio wielkościami charakteryzującymi falę elektromagnetyczną równaniem:

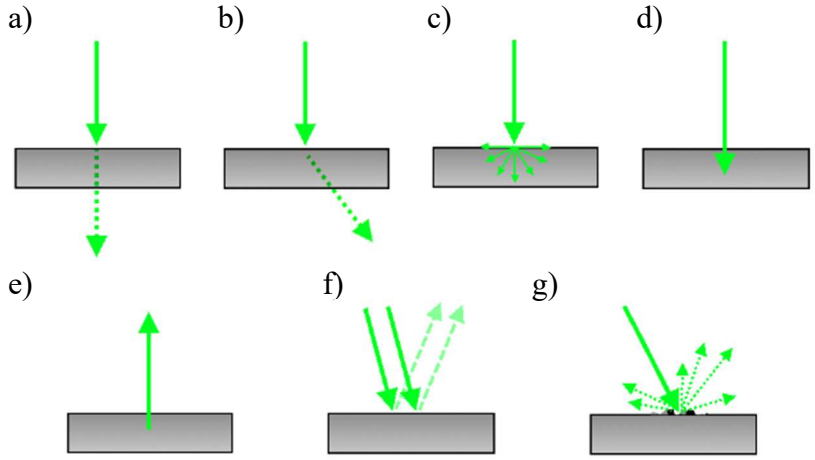
$$E = h \cdot \nu = h\frac{c}{\lambda} \tag{1}$$

gdzie:

h – stała Planka ($6{,}62 \cdot 10^{-34}$ J·s),

c – prędkość światła ($3 \cdot 10^{8}$ m/s).

W celu obrazowania właściwości fizycznych obiektów wykorzystywane są różne interakcje (Rys. 5) promieniowania elektromagnetycznego z materią [21]. W praktyce rzadko spotykane są przypadki, kiedy dane zjawisko występuje niezależnie. Zazwyczaj rejestrowane obrazy są efektem nałożenia się na siebie co najmniej dwóch rodzajów oddziaływań [48]. W zależności od zastosowanej długości fali oraz właściwości badanego obiektu, określone mechanizmy oddziaływania mogą mieć dominujący lub znikomy wpływ na proces obrazowania.



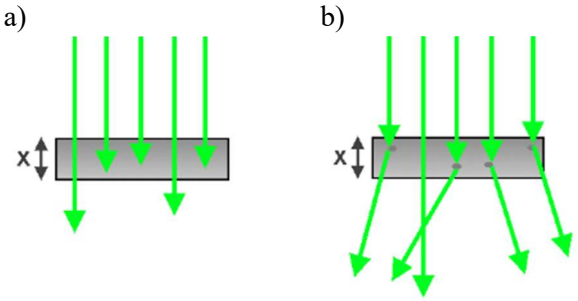
Rys. 5. Rodzaje interakcji promieniowania EM: a) transmisja b) refrakcja c) dyfuzja d) absorpcja e) emisja f) odbicie kierunkowe g) odbicie rozproszone

Interakcja danego materiału na oddziaływanie promieniowania optycznego zależy między innymi od jego stałych optycznych do których zaliczane są [49]:

- ε – przenikalność elektryczna,
- σ – przewodność elektryczna,
- χ, – podatność elektryczna,
- n – współczynnik załamania ośrodka,
- κ – współczynnik wygaszenia,
- δ – głębokość wnikania,
- Z – impedancja powierzchniowa.

Wymienione czynniki nie są stałe ani niezależne, są funkcją między innymi częstotliwości, temperatury, ciśnienia, zewnętrznego pola magnetycznego.

W systemach wizyjnych często wykorzystywanym zjawiskiem jest zmiana intensywności promieniowania przenikającego przez obiekt inspekcji. W ogólnym ujęciu proces ten może zachodzić w wyniku absorpcji (Rys. 6a) lub rozpraszania fali elektromagnetycznej (Rys. 6b).



Rys. 6. Proces tłumienia promieniowania w wyniku interakcji z materią spowodowany przez a) absorpcję b) rozpraszanie

W obydwu przypadkach wartość promieniowania transmitowanego maleje wykładniczo wraz ze wzrostem przebytej drogi x przez jednorodne ciało stałe lub ciecz [50]. Zależność tę przedstawiają wzory (2) i (3), które wyrażają prawdopodobieństwa procesu absorpcji lub rozproszenia wiązki promieniowania w danym medium. Współczynniki absorpcji i rozpraszania są nie tylko zależne od gęstości i struktury materiału, ale również od długości fali elektromagnetycznej.

$$I=I_0 \cdot 10^{-\alpha x} \text{ – dla absorpcji promieniowania} \quad (2)$$

$$I=I_0 \cdot e^{-\tau x} \text{ – dla rozpraszania promieniowania} \quad (3)$$

gdzie:

I_0 – wartość intensywności przed procesem tłumienia fali elektromagnetycznej,

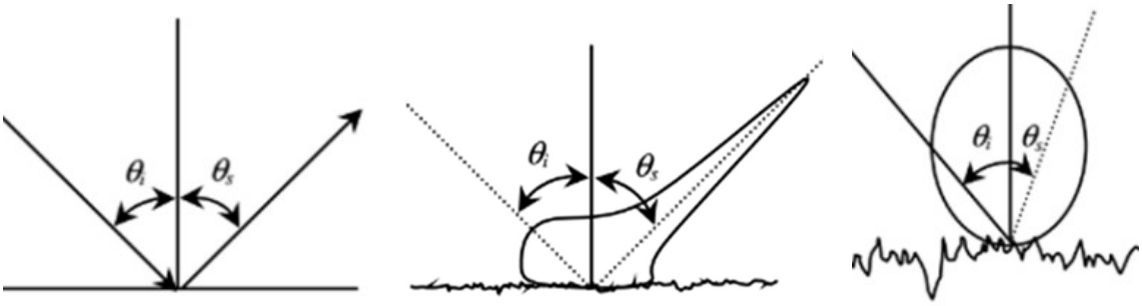
α – współczynnik absorpcji,

τ – współczynnik rozpraszania.

Rozpraszanie fali elektromagnetycznej w ogólnym ujęciu może być opisane jako zmiana jej kierunku. Jeżeli rozpraszanie zachodni na granicy dwóch ośrodków uznawanych za jednorodne, proces ten może być opisany jako rozpraszanie powierzchniowe. W przypadku gdy jeden z ośrodków nie jest jednorodny lub składa się z wielu materiałów o różnych właściwościach dielektrycznych zagadnienie takie określane jest jako rozpraszanie objętościowe [51]. W większości przypadków występują obydwa rodzaje rozpraszania, jednak w zależności od właściwości danego materiału, jeden z nich ma charakter dominujący. Rozpraszanie powierzchniowe może przyjmować różne formy, które zależą od stopnia chropowatości powierzchni. Dla powierzchni gładkiej (Rys. 7a) występuje odbicie kierunkowe, które opisują równania odbicia Fresnela. Wraz ze wzrostem nierównomierności powierzchni

dla promieniowania o tej samej długości fali, rozpraszanie zmienia swoją formę stopniowo na odbicie mieszane (Rys. 7b), aż do odbicia dyfuzyjnego (Rys. 7c).

a) b) c)



Rys. 7. Zależność udziału odbicia kierunkowego i dyfuzyjnego przy różnej chropowatości powierzchni: a) gładka b) nieznaczna chrapowatość b) wysoka chropowatość [51]

Precyzyjne określenie rodzaju rozpraszania powierzchniowego w zależności od stopnia chropowatości jest zagadnieniem skomplikowanym. Zakładając, że proces ten zachodzi w wyniku promieniowania padającego z ośrodka, którym jest powietrze lub próżnia, można zdefiniować przybliżone wartości dla jakich występować będzie określony rodzaj odbicia. Pomijając wpływ kąta padania na powierzchnię i wyznaczając optyczną chropowatość powierzchni OSR (4), według zależności:

$$OSR = \frac{2\pi h}{\lambda} \tag{4}$$

gdzie:

λ – długość fali elektromagnetycznej

h – RMS chropowatość powierzchni.

Można przyjąć następującą klasyfikację powierzchni, która porządkuje je według ich właściwości geometrycznych [52]:

- powierzchnia gładka dla OSR < 1,
- powierzchnia o wysokiej chropowatości OSR > 5.

Praktyczne wykorzystanie zjawiska rozpraszania światła do pomiaru wysokości nierówności powierzchni zostało zapoczątkowane przez Bennetta i Porteusa, którzy zbudowali pierwszy układ działający na zasadzie pomiaru całkowitej mocy promieniowania rozproszonego przez powierzchnię TIS (*ang. Total Integrated Scatter*) [53]. Rozpraszanie promieniowania jest wykorzystywane ponadto w detekcji niewielkich wad powierzchniowych oraz cząsteczek zanieczyszczeń znajdujących się na gładkich powierzchniach [54].

Zjawisko rozpraszania promieniowania przez pojedyncze cząsteczki zależy od następujących czynników:

- wielkości cząsteczki,
- polaryzacji wiązki promieniowania,
- kształtu cząsteczki,

- współczynnika refrakcji.

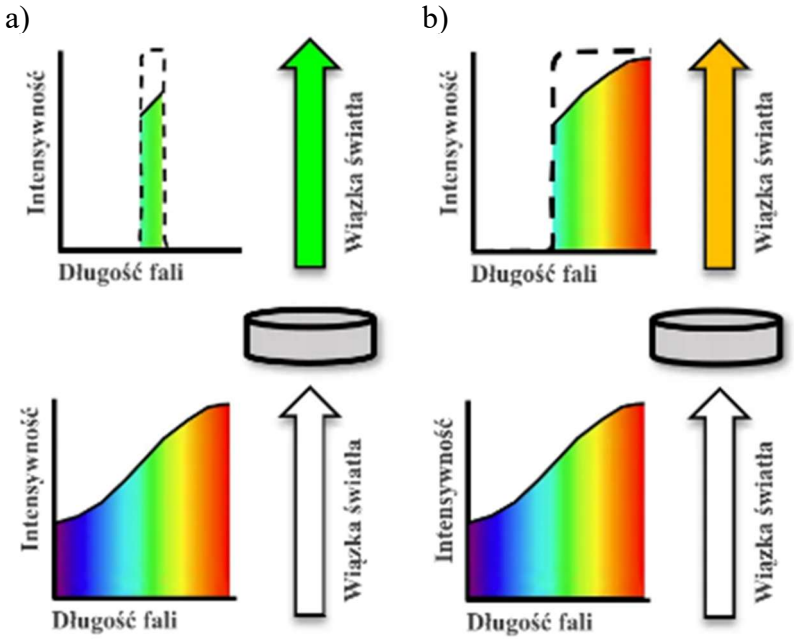
Rysunek 8 przedstawia uproszczoną reprezentację łącznego oddziaływania odbicia powierzchniowego oraz rozpraszania na cząsteczkach [54].



Rys. 8. Rozpraszanie promieniowania przez cząsteczki na powierzchni

Wady powierzchniowe w postaci wgłębień i wypukłości powodują zbliżone zjawiska optyczne jak w przypadku rozpraszania fali przez pojedyncze cząsteczki znajdujące się na powierzchni obiektu. Przyjmuje się, że ilość promieniowania rozpraszanego przez nierównomierności może być wyrażona jako ekwiwalent rozpraszania przez pojedyncze cząsteczki o danej średnicy. W celu uzyskania wartości referencyjnych intensywności rozpraszanego promieniowania wykorzystywane są testowe sferyczne cząsteczki PSL *(ang. Polystyrene Latex*) [55].

Drugim zjawiskiem fizycznym, które ma wpływ na tłumienie promieniowania przenikającego przez materię jest absorpcja. Pole elektryczne promieniowania elektromagnetycznego wywiera siły na ładunki elektryczne i dipole znajdujące się w atomach, molekułach oraz ciałach stałych, powodując ich wibrację i przyśpieszanie [56]. W wyniku takiego rodzaju oddziaływania następuje absorpcja fali elektromagnetycznej. Absorpcja promieniowania przez materię jest bardzo istotnym rodzajem interakcji, który w dużym stopniu decyduje o wartości przezroczystości obiektu dla danego zakresu spektrum elektromagnetycznego. Zjawisko to wykorzystywane jest w praktyce między innymi w budowie filtrów optycznych. Filtr pasmowo–przepustowy umożliwia transmisję wąskiego zakresu, blokując pozostałe długości fali (Rys. 9a). Innym przykładem jest filtr, który selektywnie transmituje promieniowanie o długościach fali wyższych niż ustalona wartość progowa (Rys. 9b).



Rys. 9. Zasada działania filtru a) pasmowo–przepustowego b) górnoprzepustowego [57]

Ze względu na występowanie składowej elektrycznej fali elektromagnetycznej bardzo istotny wpływ na rodzaj jej oddziaływania z materią mają właściwości elektryczne obiektu badań. Ciała stałe można podzielić na przewodniki, półprzewodniki i dielektryki, które różnią się wielkością przerwy energetycznej pomiędzy stanami energetycznymi elektronów.

W przewodnikach elektrony w wyniku oddziaływania zewnętrznego pola elektrycznego, poruszają się powodując przepływ prądu i tak zwane zjawisko naskórkowości. Miarą jak daleko fala elektromagnetyczna może przenikać jest wartość głębokości wnikania δ (*ang. skin depth*) [58], wyrażona wzorem (5).

$$\delta = \sqrt{\frac{2}{\omega \cdot \mu \cdot \sigma}} \tag{5}$$

gdzie:

σ – przewodność materiału,

ω – pulsacja kątowa,

f – częstotliwość,

μ – bezwzględna przenikalność magnetyczna.

Jak można zauważyć głębokość wnikania promieniowania δ jest odwrotnie proporcjonalna do wartości częstotliwości i przewodności materiału. W wyniku tego przenikanie promieniowania o krótszej długości fali, szczególnie dla dobrych przewodników jest znacząco ograniczone. W tabeli 2 przedstawione zostały wartości głębokości wnikania fali elektromagnetycznej w zależności od jej częstotliwości w głąb próbki wykonanej z miedzi.

Tabela 2. Głębokość wnikania fali elektromagnetycznej w miedzi

Częstotliwość [Hz]	10	100	500	10^4
Głębokość δ [mm]	20.8	6.6	2.99	0.66

Dla większości metali wielkość głębokości wnikania fali, w zakresie częstotliwości promieniowania optycznego wynosi maksymalnie około 50 nm [59]. Po przeniknięciu wiązki promieniowania na ten dystans jej intensywność maleje do 13.5% wartości jaką posiadała na powierzchni materiału. W związku z tym można założyć, że w przypadku zastosowania promieniowania optycznego w kontroli jakości, poza szczególnymi przypadkami, obiekty metalowe są nieprzezroczyste i w wyniku interakcji z nimi energia fali elektromagnetycznej zostaje niemal całkowicie odbita lub zabsorbowana.

W przypadku dielektryków przerwa energetyczna ma wartość powyżej 3,2 eV, co odpowiada zakresowi pasma promieniowania ultrafioletowego. Dielektryki o budowie krystalicznej wykorzystywane są często jako materiały optyczne do konstrukcji m.in. soczewek i zwierciadeł. Charakterystyka danego materiału może się różnić w szczegółach jednak najważniejsze cechy tego rodzaju materiałów można opisać w następujący sposób [60]:

- większość dielektryków o budowie krystalicznej, w zakresie pasma światła widzialnego jest transparentna i bezbarwna. Promieniowanie ultrafioletowe i podczerwone jest natomiast silnie tłumione,
- w obszarze transparentności współczynnik absorpcji jest bardzo mały, natomiast współczynnik załamania posiada jedynie składową rzeczywistą, bez części urojonej i jest w przybliżeniu stały,
- współczynnik transmisyjności w obszarze transparentności zależy od refleksyjności powierzchni, która określona jest przez współczynnik załamania.

W półprzewodnikach przerwa energetyczna jest na tyle niewielka, że możliwa jest absorpcja termiczna fotonu, którego energia wzbudza stany oscylacyjne i rotacyjne w cząsteczkach lub sieci krystalicznej materiału. Dodatkowo w zakresie podczerwieni dla niektórych materiałów możliwa jest absorpcja poprzez wzbudzenie elektronu na wyższy poziom energetyczny [61].

2.2. Rodzaje i klasyfikacje metod inspekcji optycznej

Spectrum promieniowania optycznego składa się z czterech pasm: promieniowania ultrafioletowego, widzialnego, podczerwieni i terahercowego. Regiony te podzielone są na dalsze segmenty. Podział ten został ukształtowany poprzez istnienie obszarów promieniowania elektromagnetycznego, które są silnie tłumione przez cząsteczki zawarte w atmosferze ziemskiej. Wynika to również z charakterystyki spektralnej istniejących obecnie sensorów, które cechują się wysoką czułością w ograniczonych zakresach promieniowania

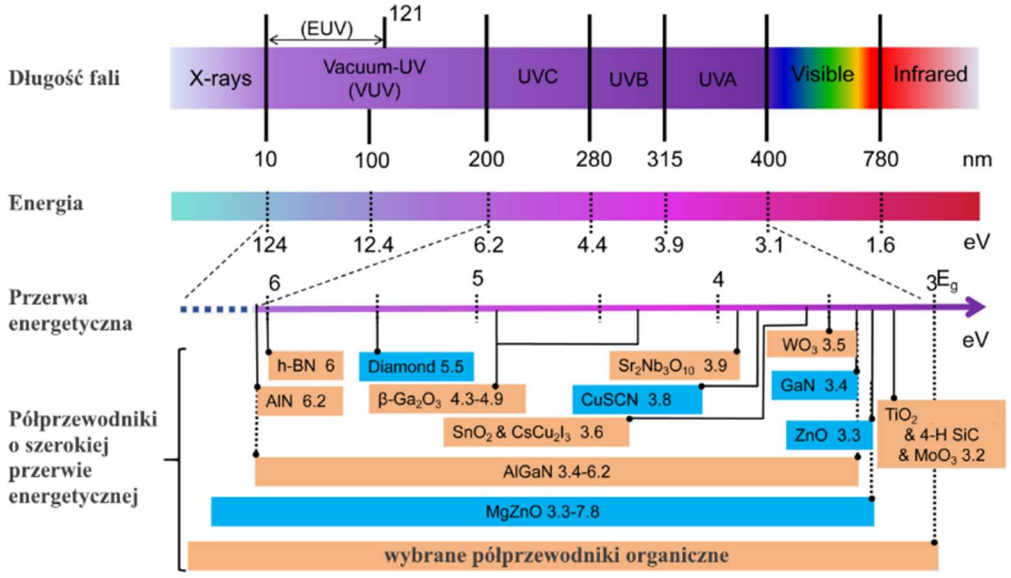
elektromagnetycznego [62]. Dodatkowym wyzwaniem jest również trudność w opracowaniu elementów optyki systemu wizyjnego, zapewniających dużą transmisyjność promieniowania w szerokim zakresie promieniowania. Podczas opracowywania systemów hybrydowych istotna jest znajomość właściwości poszczególnych pasm spektrum promieniowania optycznego oraz ich poszczególnych segmentów, w celu osiągnięcia wysokiej skuteczności systemu detekcji.

Promieniowanie ultrafioletowe

Zakres ultrafioletowy UV (*ang. ultraviolet*) spektrum elektromagnetycznego obejmuje fale o długości krótszej niż światło widzialne, w przybliżeniu od 400 do 10nm. Znaczna część pasma ultrafioletowego ma charakter niejonizujący. Jednak długa ekspozycja na promieniowanie UV, bez odpowiedniej ochrony, może powodować oparzenia, przyśpieszać proces starzenia skóry i zwiększać ryzyko raka. Fale ultrafioletowe mogą też spowodować uszkodzenie siatkówki oka i zaćmę [63]. Ze względu na różne czynniki zakres promieniowania ultrafioletowego podzielony został na mniejsze obszary. Według biologów pasmo ultrafioletowe dzieli się na następujące segmenty, które różnią się pod względem stopnia oddziaływania na organizm ludzki [64]:

- UV–A 315 nm >λ≥ 400 nm,
- UV–B 280 nm > λ≥ 315 nm,
- UV–C 100 nm >λ≥ 280 nm.

Przedstawiony podział pasma UV jest zgodny ze standardami komisji CIE (*ang. International Commission on Illumination*). Często jednak można się spotkać podziałem, gdzie granica pomiędzy UV–A i UV–B wynosi 320nm. Ze względu na właściwości fizyczne wyróżnić można kilka konwencji podziału pasma ultrafioletowego na podobszary (Rys.10), których granice nie są jednakowe [26].



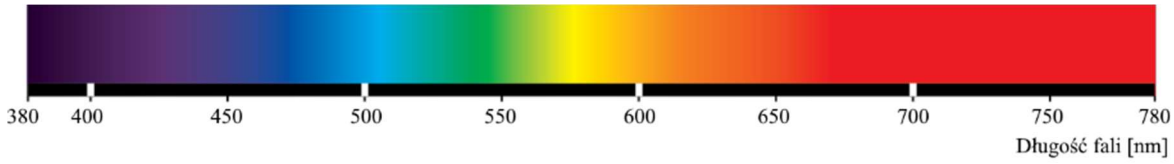
Rys. 10. Podzakresy promieniowania ultrafioletowego [65]

W zastosowaniach w kontroli jakości powierzchni elementów elektronicznych często wykorzystywanym terminem jest głęboki ultrafiolet (*ang. deep UV*), którego zakres wynosi od 250 do 115 nm. Określenie ekstremalne promieniowanie ultrafioletowe (*ang. extreme UV*) dotyczy natomiast fal o długości w zakresie 10 nm > λ ≥ 121 [65]. Wyróżnia się również promieniowanie UV próżniowe (*ang. vacuum UV*), które obejmuje zakres fal o długości krótszej niż 180 nm. Ze względu na wysoką absorpcję tego rodzaju promieniowania przez powietrze, systemy, w których wykorzystywane są długości fal z tego segmentu pasma UV, wymagają wytworzenia próżni lub innej atmosfery o wyższej transmisyjności.

Zastosowanie promieniowania ultrafioletowego (UV) w systemach wizyjnych, umożliwia wizualizację cech i właściwości obiektów, które są trudne do zobrazowania za pomocą innych metod. Wiele typów substancji wykazuje silną absorpcję dla tego rodzaju promieniowania. Z tego względu możliwa jest m.in. wizualizacja topografii powierzchni materiałów, które są transparentne lub półprzezroczyste dla pasma widzialnego. Ponadto ze względu na krótsza długość fali, promieniowanie UV ulega w znacznie większym stopniu niż w przypadku pasma widzialnego lub podczerwieni rozproszeniu w wyniku interakcji z nierówną powierzchnią. Dzięki temu możliwa jest detekcja drobnych rys lub pęknięć niewidocznych przy zastosowaniu innego rodzaju oświetlenia. Ponadto promieniowanie ultrafioletowe jest silnie absorbowane przez substancje takie jak m.in. oleje. Z tego względu systemy UV wykorzystywane są do detekcji zanieczyszczeń na różnego rodzaju powierzchniach [66]. Jedną z najczęściej wykorzystywanych cech promieniowania ultrafioletowego jest właściwość materiałów, pozwalająca na uzyskanie efektu fluorescencji. W metodach bazujących na tym zjawisku, obiekt badań zostaje oświetlony z wykorzystaniem promieniowania UV, następnie za pomocą kamery pasma widzialnego rejestrowana jest emisja fotonów przez wzbudzone atomy lub cząsteczki. W systemach wykorzystujących aktywne oświetlenie ultrafioletowe stosowana jest natomiast metoda obrazowania odbiciowego [67].

Promieniowanie widzialne

Promieniowanie widzialne VIS (*ang. visible light spectrum*) to zakres spektrum elektromagnetycznego obejmujący fale o długości w przybliżeniu od 380 do 780 nm (Rys. 11), które są możliwe do zaobserwowania przez ludzki narząd wzroku [68]. Stąd też ten rodzaj promieniowania często określany jest terminem światła widzialnego.



Rys. 11. Spektrum promieniowania widzialnego [69]

Poszczególnym długościom fal odpowiadają kolejno następujące po sobie barwy, które dzielą pasmo światła widzialnego na segmenty. Siatkówka oka jest najbardziej czuła na fale

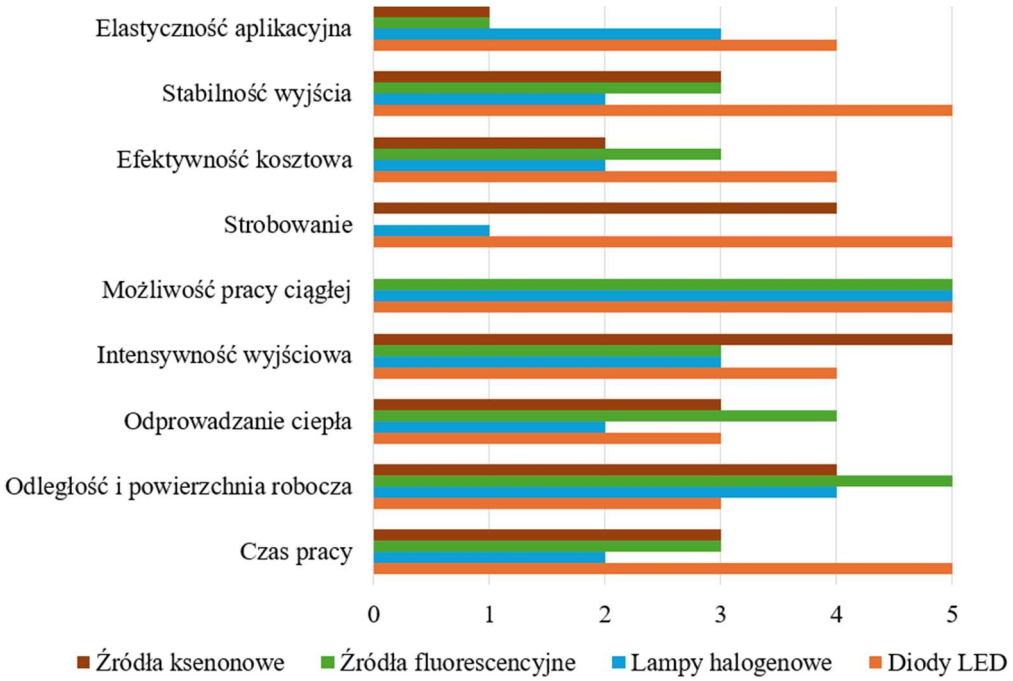
o długości zbliżonej do 550 nm, które odpowiadają barwie żółto–zielonej. Często spotykanym terminem jest światło białe, które jest równomierną mieszanką wszystkich długości fali w zakresie widzialnym. Światło monochromatyczne [70] w dosłownym tłumaczeniu z łaciny oznacza światło jedno–kolorowe. Jest to wyidealizowane pojęcie oznaczające promieniowanie o pojedynczej częstotliwości fali. W praktyce światło klasyfikowane jako monochromatyczne składa się z wielu fal o częstotliwości zbliżonej do nominalnej, reprezentatywnej barwy światła.

Promieniowanie widzialne jako pierwsze stosowane było w systemach obrazowania i obecnie znajduje szerokie zastosowanie w przemysłowych systemach wizyjnych. Szczególną cechą pasma widzialnego jest natomiast możliwość identyfikacji kolorów. Zagadnienie to odnosi się do dwóch rodzajów metod [68]. Pierwsza grupa związana jest z postrzeganiem barw *(ang. color appearance),* przez człowieka i teoriami widzenia barwnego [71]. Techniki dopasowywania kolorów *(ang. color matching)* mogą być natomiast wykorzystywane do bardzo precyzyjnego określenia barw. Dziedzina, w której wykorzystywane są techniki mające na celu identyfikację kolorów, nazywana jest kolorymetrią. Bezkontaktowe metody pomiarowe wykorzystujące pasmo widzialne najczęściej stosowane są w procesach inspekcji obejmujących [22]:

- kontrolę kształtu i wymiarów geometrycznych,
- kontrolę kompletności,
- inspekcję powierzchni,
- porównywanie obiektów i obrazów,
- identyfikację obiektów (za pomocą kodów, znaczników).

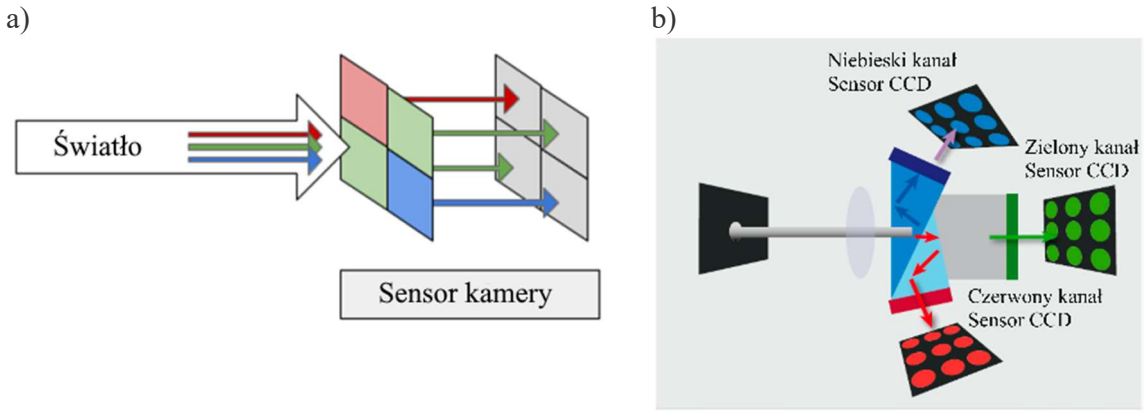
W związku z tym, że systemy wizji maszynowej, w większości przypadków, wykorzystują zakres promieniowania widzialnego, elementy wchodzące w skład tego rodzaju układów obrazowania (sensory, źródła, układy optyczne), są rozwijane od wielu lat i osiągnęły obecnie bardzo wysoki poziom zaawansowania technologicznego.

Jako pierwsze w systemach maszynowego widzenia wykorzystywane były źródła fluorescencyjne i halogenowe. Aktualnie najczęściej stosowane jest oświetlenie LED co wynika z bardzo dobrych cech użytkowych (Rys. 12) obejmujących niski pobór mocy, trwałość i odporność mechaniczna [72]. Ponadto niewielki rozmiar pojedynczych diod LED, umożliwia swobodne projektowanie kształtu oświetlaczy. Istotny jest również duży wybór zakresów spektralnych oświetlaczy, poza źródłami światła białego, możliwy jest precyzyjny dobór zakresu emitowanych fal w celu uzyskania pożądanej barwy.



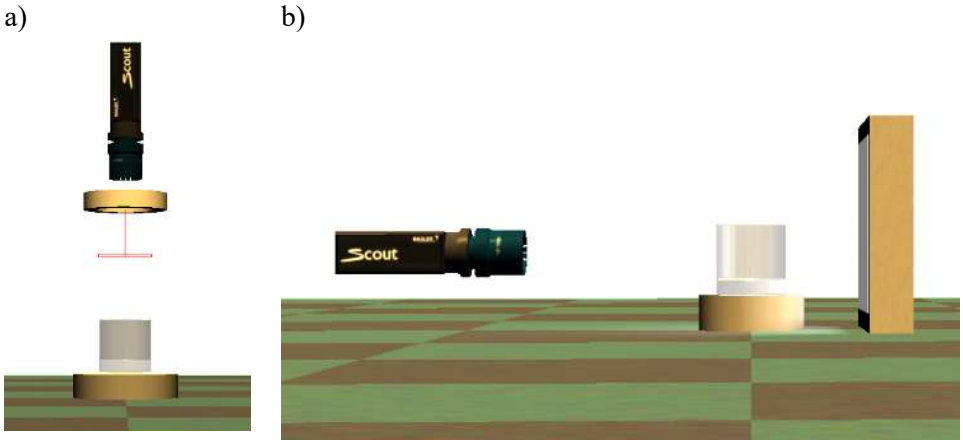
Rys. 12. Porównanie cech użytkowych oświetlaczy [72]

Od momentu wprowadzenia technologii cyfrowej do kamer w latach 70 XX wieku obserwuje się nieustanny postęp w rozwoju sensorów wykorzystywanych w systemach maszynowego widzenia [73], czego efektem jest zarówno zwiększenie prędkości akwizycji obrazów, jak i wzrost ich rozdzielczości. W systemach wizyjnych wykorzystujących promieniowanie widzialne, stosowane są głównie dwa rodzaje matryc światłoczułych: CCD (*ang. Charge Coupled Device*) oraz CMOS (*ang. Complementary Metal-Oxide Semiconductor*). Zakres czułości spektralnej tego rodzaju sensorów wynosi od 350 do 1050 nm. Systemy kontroli jakości, które bazują na analizie kolorów wymagają zastosowania sensorów o specjalnej budowie. Standardowe matryce światłoczułe wykorzystujące efekt fotoelektryczny, nie odróżniają promieniowania o danej barwie. W celu uzyskania obrazów kolorowych najczęściej stosowana metoda polega na zastosowaniu matrycy światłoczułej wyposażonej w filtr Bayera (Rys. 13a). W tego typu rozwiązaniu światło docierające do sensora kamery przenika przez siatkę filtrów optycznych o barwie czerwonej, zielonej i niebieskiej [74]. Kombinacja sygnałów z sąsiadujących ze sobą pikseli RGB jest konwertowana na odpowiedni kolor rejestrowany na obrazach. Konieczność zastosowania większej liczby pikseli w celu uzyskania informacji barwnej skutkuje zmniejszoną rozdzielczością kamer o takiej budowie w stosunku do kamer monochromatycznych. Innym rozwiązaniem umożliwiającym rejestrowanie obrazów kolorowych jest potrójna matryca światłoczuła (Rys 13b). W kamerach tego rodzaju stosowane są trzy matryce światłoczułe z filtrami dla barw czerwonej, zielonej i niebieskiej oraz pryzmat [75]. Dzięki takiemu rozwiązaniu możliwe jest uzyskanie większej rozdzielczości obrazu jednak taki układ obrazowania charakteryzuje się mniejszą czułością.



Rys. 13. Budowa kamery kolorowej a) z filtrem Bayera b) kamera 3xRGB. [76], [77]

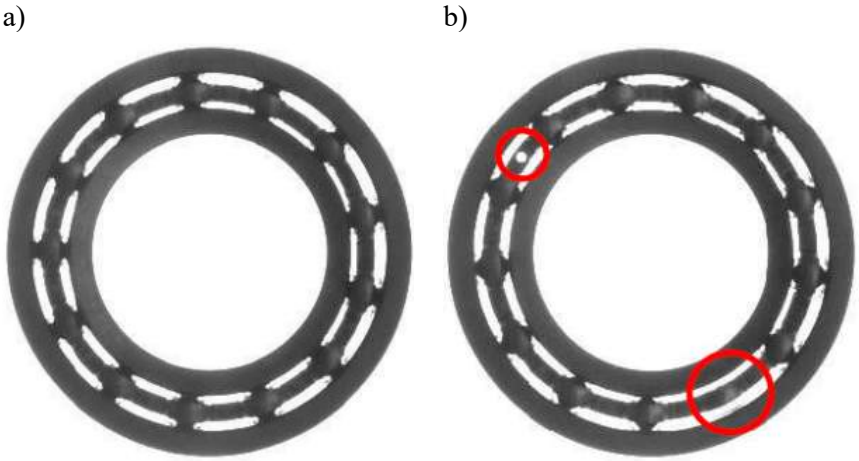
Podczas projektowania przemysłowych systemów wizyjnych głównym celem jest maksymalizacja kontrastu pożądanych cech obserwowanego obiektu, przy jednoczesnej minimalizacji kontrastu na pozostałych obszarach rejestrowanych obrazów [78]. Prawidłowe zaprojektowanie układu obrazowania ma decydujący wpływ na niezawodność i powtarzalność systemów wizyjnego. Podstawową metodą akwizycji obrazów w paśmie widzialnym jest obrazowanie odbiciowe (Rys. 14a), w którym kamera rejestruje promieniowanie widzialne odbite od obiektu inspekcji. Taka metoda obrazowania ma zastosowanie w pomiarach geometrycznych oraz detekcji wad powierzchniowych produktów [79].



Rys. 14. Układ akwizycji obrazów a) refleksyjny b) układ transmisyjny

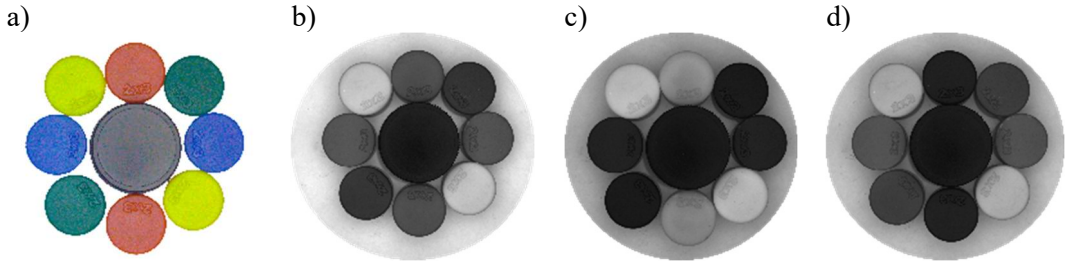
W systemie obrazowania w układzie transmisyjnym (Rys. 14b) obiekt badań zostaje oświetlony w kierunku kamery, która rejestruje docierające do niej promieniowanie. Tego rodzaju konfiguracja określana jest terminem oświetlenia wstecznego (*ang.* back–light). W przypadku nieprzezroczystych obiektów inspekcji metoda ta jest wykorzystywana najczęściej do pomiaru zewnętrznych wymiarów produktu [80] lub kontroli kompletności wyrobów złożonych (Rys. 15). Podczas inspekcji materiałów transparentnych analizowane jest natomiast światło rejestrowane przez sensor kamery w wyniku transmisji przez strukturę obiektu. Umożliwia to detekcję wad podpowierzchniowych takich jak uszkodzenia struktury

wewnętrznej i wtrącenia. Ponadto przy zastosowaniu oświetlenia wstecznego strukturalnego (*ang. structured backlight*), możliwa jest detekcja deformacji geometrycznych w produktach transparentnych [81].



Rys. 15. Inspekcja poprawności montażu łożysk kulkowych z wykorzystaniem oświetlenia wstecznego (*ang. backlight*) a) produkt prawidłowy b) produkt wadliwy [82]

W systemach wizyjnych mających na celu detekcję obiektów o określonej barwie, stosowana może być metoda koła barw (Rys.16). Światło o określonej barwie, pozwala na osiągniecie wysokiego kontrastu podczas inspekcji obiektów kolorowych.

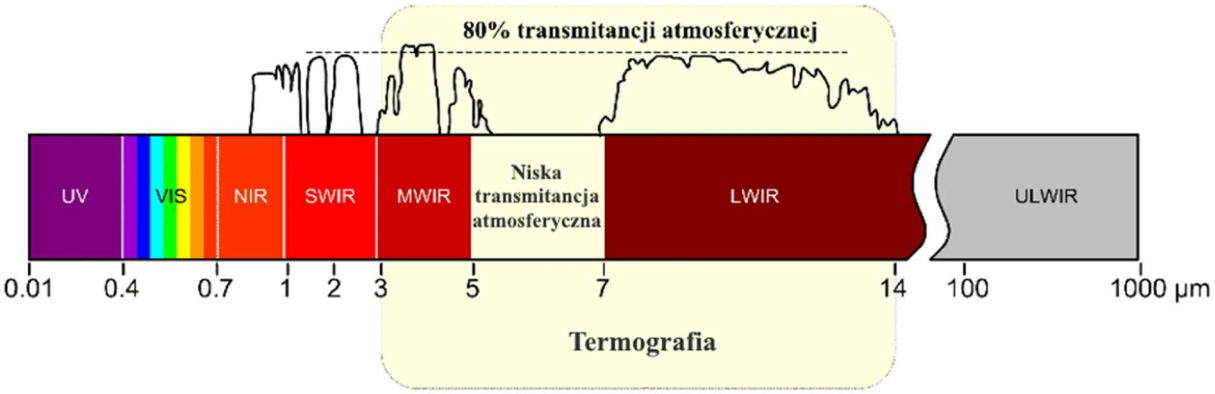


Rys. 16. Metoda koła barw – obrazy z kamery a) RGB b) monochromatycznej i oświetlacza barwy białej c) monochromatycznej i oświetlacza barwy czerwonej d) monochromatycznej i oświetlacza barwy zielonej

Zastosowanie barwy przeciwstawnej do koloru obiektu podlegającego inspekcji powoduje, że na zarejestrowanych przez kamerę monochromatyczną obrazach będzie on widoczny jako ciemniejszy. Zastosowanie oświetlenia o tej samej barwie jaką posiada obiekt inspekcji spowoduje, że będzie on na obrazie widoczny jako jaśniejszy. System wykorzystujący technikę koła barw może być zrealizowany z wykorzystaniem oświetlacza o wybranej barwie lub oświetlacza barwy białej i filtru pasmowo–przepustowego.

Promieniowanie podczerwone

Przyjmuje się, że widmo promieniowania podczerwonego IR (*ang. infrared radiation*) obejmuje pasmo fal o długości fali powyżej 0,78 µm. Górna granica tego pasma, zależnie od źródeł, sięga nawet 1000 µm, co jest charakterystyczne zwłaszcza dla starszych publikacji nieuwzględniających wydzielonego obecnie pasma terahercowego [83]. W nowszej literaturze zakres promieniowania podczerwonego jest często ograniczany do długości fal rzędu 30 µm. Ze względu na specyficzne cechy obrazowania w zależności od długości fal, pasmo podczerwieni zostało podzielone na podzakresy. Międzynarodowa komisja oświetleniowa CIE, stosuje podział promieniowania podczerwonego, na trzy podzakresy IR–A (0,7–1,4 µm), IR–B (1,4–3 µm), IR–C (3–1000 µm), które w różnym stopniu wpływają na organizm ludzki. Skutki biologiczne są uwarunkowane intensywnością promieniowania, wielkością pochłoniętej dawki oraz rodzajem eksponowanej tkanki. Ze względu na czułość materiałów wykorzystywanych do produkcji sensorów kamer, zakres podczerwieni może być natomiast podzielony na podzakresy przedstawione na rysunku 17. W przemysłowych systemach inspekcji wykorzystuje się komercyjnie dostępne kamery pracujące w zakresach widma NIR, SWIR, MWIR oraz LWIR.



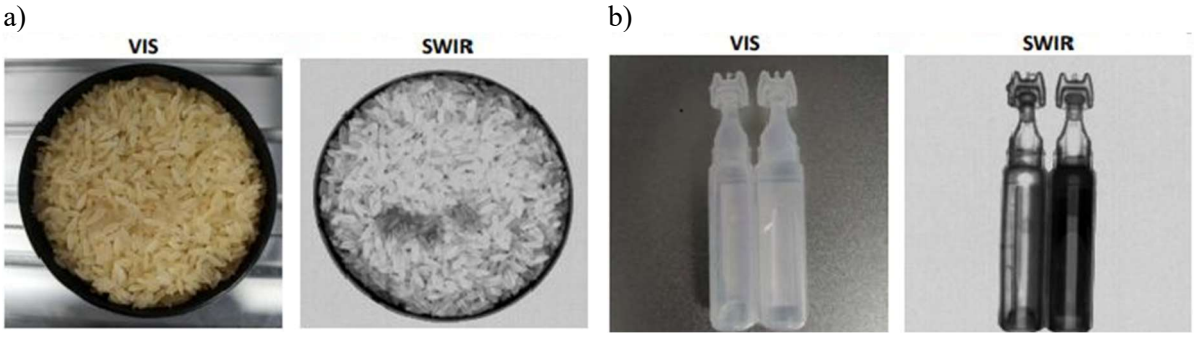
Rys. 17. Zakres promieniowania podczerwonego [84]

Obszar podczerwieni w widmie elektromagnetycznym można podzielić na pięć podzakresów, obejmujących [85]:

- bliską podczerwień (NIR),
- podczerwień krótkofalową (SWIR),
- podczerwień średniofalową (MWIR),
- podczerwień długofalową (LWIR),
- bardzo daleką podczerwień (VLWIR).

Systemy wykorzystujące promieniowanie podczerwone mogą być ogólnie podzielone na układy obrazowania fali elektromagnetycznej transmitowanej, odbitej od obiektu lub wyemitowanej przez niego w związku z zachodzącymi w nim procesami termodynamicznymi. Promieniowanie podczerwone odbiciowe (*ang. reflected infrared*) obejmuje zakres

podczerwieni krótkofalowej [86]. Podobnie jak w przypadku promieniowania widzialnego, w tego rodzaju systemach, w celu zobrazowania obiektu konieczne jest jego oświetlenie. Metody inspekcji tego rodzaju wykorzystują stosunkowo niższą absorpcję promieniowania podczerwonego przez wiele materiałów w stosunku do światła widzialnego oraz mniejsze rozpraszanie promieniowania na powierzchni obiektu wynikające z dłuższej długości fali. Przykładem wykorzystania opisanych cech promieniowania NIR jest obrazowanie promieniowania podczerwonego transmitowanego [87] oraz reflektografia stosowana w badaniach nieniszczących dzieł sztuki [88]. Technika ta opiera się na promieniowaniu, które przenika przez warstwy farby i odbija się od podłoża. Uzyskiwane wyniki zależą od współczynnika absorpcji tego promieniowania przez poszczególne pigmenty W przemyśle często wykorzystywana jest natomiast wysoka absorpcja wielu płynów w paśmie SWIR, która umożliwia uzyskanie wysokiego kontrastu na rejestrowanych obrazach. Układy obrazowania tego typu mogą być zastosowane do inspekcji stopnia zawilgocenia (Rys. 18a) lub pomiaru poziomu cieczy (Rys. 18b). Przeprowadzenie tego rodzaju inspekcji w zakresie światła widzialnego byłoby niemożliwe ze względu na brak odpowiednich właściwości badanych materiałów.



Rys. 18. Przykłady zastosowań obrazowania SWIR a) kontrola zawilgocenia w produktach spożywczych b) kontrola poziomu cieczy w opakowaniach

Mimo stale zwiększającej się liczby systemów obrazowania odbiciowego NIR, wynikającej m.in. z rozwoju sensorów CMOS, obecnie najczęściej promieniowanie podczerwone wykorzystywane jest w celu obrazowania procesów cieplnych zachodzących w obserwowanych obiektach. W tego rodzaju systemach wykorzystywane jest promieniowanie elektromagnetyczne z zakresu podczerwieni średnio i długofalowej, który często określany jest jako podczerwień termalna (TIR – thermal infrared) [89].

Efektem wymiany energii cieplnej pomiędzy ośrodkami jest ruch elektronów lub wzrost wibracji atomów lub cząsteczek w substancji. Istnieją trzy możliwe sposoby wymiany energii cieplnej: przewodzenie, konwekcja lub promieniowanie [90].

Przewodzenie cieplne (kondukcja) – jest wynikiem interakcji wysokoenergetycznych i niskoenergetycznych cząsteczek znajdujących się w bliskim sąsiedztwie, co skutkuje wymianą energii. Przewodzenie ciepła może odbywać się zarówno w gazach, cieczach jak i ciałach stałych. W płynach kondukcja zachodzi na skutek kolizji oraz dyfuzji molekuł podczas

chaotycznego ruchu. W ciałach stałych natomiast jest wynikiem zarówno wibracji molekuł jak i transferu energii poprzez elektrony swobodne.

Konwekcja – to sposób wymiany ciepła pomiędzy powierzchnią ciała stałego, a przylegającą do niej cieczą lub gazem znajdującym się w ruchu. Skutkiem tego jest kombinacja efektu ruchu płynu oraz przewodzenia cieplnego. Im szybszy jest ruch medium tym większy jest transfer ciepła.

Promieniowanie – w przeciwieństwie do przewodzenia cieplnego oraz konwekcji, wymiana energii poprzez promieniowanie nie wymaga obecności medium pośredniczącego. W związku z tym tego rodzaju wymiana energii odbywa się z prędkością światła i w przypadku, gdy zachodzi w próżni nie ulega tłumieniu.

Detekcja promieniowania termalnego stanowi podstawę dla bezkontaktowych pomiarów temperatury oraz termografii. Każdy obiekt, którego temperatura jest wyższa niż zero absolutne (–273,15 °C), emituje promieniowanie elektromagnetyczne, które jest proporcjonalne do jego temperatury [91]. Promieniowanie termalne pochodzące od obiektu określane jest jako promieniowanie wychodzące (*ang. Exitance radiosity*), które w ogólnym przypadku jest sumą składowych promieniowania wyemitowanego, odbitego i transmitowanego przez powierzchnię obiektu. Jednak ze względu na to, że metody inspekcji wykorzystujące pomiary optyczne temperatury zazwyczaj dotyczą ciał stałych które są nieprzezroczyste, promieniowanie termalne rozważane jest często jako zjawisko powierzchniowe [92].

Maksymalna ilość promieniowania, które może być wyemitowane przez powierzchnię obiektu w temperaturze T_s jest określona prawem Stefana–Boltzmanna:

$$Q_{emit,max} = \sigma A_s T_s^4 \tag{6}$$

gdzie:

σ – stała Boltzamna,

A_s– powierzchnia emitująca promieniowanie.

Model ciała, które emituje maksymalnie możliwą ilość promieniowania dla danej temperatury, nazywany jest ciałem doskonale czarnym. Jest ono idealnym absorberem, pochłania całe padające na nie promieniowanie, niezależnie od długości fali. Rozkład widmowy promieniowania elektromagnetycznego emitowanego przez takie ciało zależy wyłącznie od jego temperatury i opisują go prawa Plancka, Wiena oraz Stefana-Boltzmanna [93]. Zależność tę określa prawo Plancka:

$$W_\lambda = \frac{2\pi hc^2}{\lambda^5}\left(e^{hc/\lambda kT} - 1\right)^{-1} \tag{7}$$

gdzie:

h – stała Plancka,

c – prędkość światła,

k – stała Boltzmanna,

T – temperatura absolutna ciała czarnego,

λ – długość fali promieniowania.

Długość fali, odpowiadająca maksymalnej wartości promieniowania ciała doskonale czarnego, może być wyznaczona za pomocą prawa przesunięć Wiena [94]:

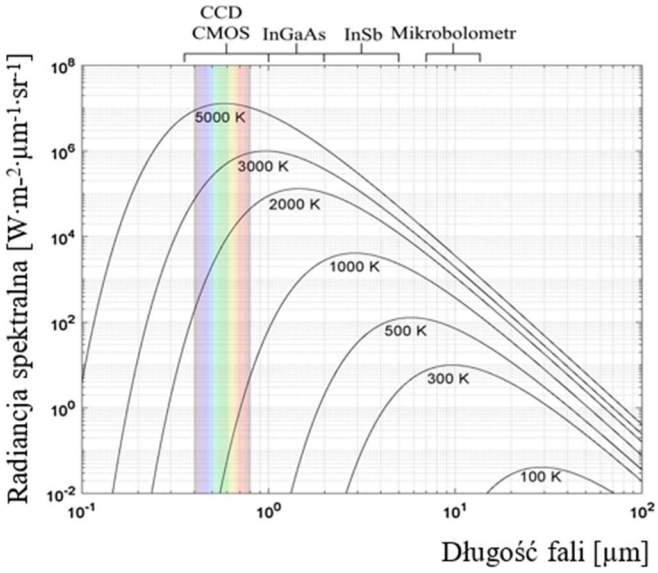
$$\lambda_{max} = \frac{A}{T} \tag{8}$$

gdzie:

T – temperatura bezwzględna [K]

A – stała Wiena, wynosząca 2897,8 [µm K]

Na rysunku 19 przedstawiono rozkład energii promieniowania w funkcji długości fali dla różnych temperatur ciała doskonale czarnego. Wraz ze wzrostem temperatury maksimum krzywej przesuwa się w stronę krótszych fal, a całkowita emitowana energia rośnie. Oznacza to, że im wyższa temperatura obiektu, tym większa jest wartość maksymalna promieniowania oraz tym mniejsza długość fali, przy której to maksimum występuje.



Rys. 19. Rozkład widmowy emitancji ciała doskonale czarnego [95]

Rozkład widmowy emitancji ciała doskonale czarnego oraz równanie Wiena ma istotne znaczenie praktyczne podczas doboru odpowiedniego sensora, który ma być wykorzystany do pomiaru temperatury danego obiektu [96]. Kamery LWIR są przeznaczone do pomiaru temperatury w zakresie od –70 ºC do 250 ºC. W zakresie podczerwieni SWIR wykonywane są zwykle pomiary temperatury od 250 ºC do 800 ºC. Wyższe wartości temperatury mogą być mierzone również sensora CCD i CMOS zwykle przeznaczonymi do obrazowania w zakresie widzialnym [97].

W przypadku obiektów rzeczywistych promieniowanie emitowane przez powierzchnię opisane jest zależnością (9) uwzględniającą dodatkowo emisyjność materiałów, która może przyjmować wartość w zakresie od 0<ε<1.

$$Q_{emit} = \varepsilon \sigma A_s T_s^4 \tag{9}$$

gdzie:

ε – emisyjność,

A_s – powierzchnia,

T_s – temperatura.

W tabeli 3 przedstawiono wartości emisyjności wybranych materiałów, uwzględniając stan ich powierzchni oraz zakres widmowy.

Tabela 3. Emisyjność materiałów [91]

Materiał	Stan powierzchni	Temperatura [ºC]	Spektrum	Emisyjność
Aluminium	Polerowana	50–100	pełne	0,04–0,06
	Anodowana, jasnoszary mat	70	LW	0,95
	Anodowana, jasnoszary mat	70	SW	0,67
	Szorstka	20–50	pełne	0,06–0,07
Stal	Błyszcząca	20	pełne	0,16
	Frezowana	700	pełne	0,45
	Piaskowana	700	pełne	0,7
	Polerowana	70	LW	0,14
	Utleniana w temp. 800°C.	60	pełne	0,85
Papier	Kolor czarny	20	pełne	0,9
	Kolor biały	20	pełne	0,7–0,9
Tworzywo sztuczne	laminat szklano–epoksydowy	70	LW	0,91
	PCV	70	LW	0,93

Większość systemów przemysłowych z zakresu promieniowania podczerwonego wykorzystuje w swoim działaniu metody termowizji, w których źródłem promieniowania są fale elektromagnetyczne emitowane przez obiekt podlegający inspekcji. Mimo to utrzymuje się znaczące zapotrzebowanie na urządzenia emitujące promieniowanie elektromagnetyczne w szerokim zakresie pasma podczerwieni, przeznaczone do zastosowań w układach obrazowania transmisyjnego oraz odbiciowego. Zapotrzebowanie to stymuluje ciągły rozwój technologii, w tym rozwiązań opartych na oświetlaczach LED. W zakresie bliskiej

podczerwieni, dostępne są obecnie rozwiązania techniczne umożliwiające projektowanie oświetlaczy wykonanych z diod NIR wysokiej mocy. Najczęściej stosowane emitery wykorzystują trzy długości fali: 810 nm, 850 nm oraz 940 nm [98]. Standardowe diody wykonane ze związku InGaAs mogą operować w zakresie od 1 do 1,6 μm [99]. Nowoczesne technologie LED pozwalają również na konstruowanie oświetlaczy LED operujących w zakresach 3–4 μm [100] oraz 5–10 μm [101]. Do pozostałych źródeł promieniowania podczerwonego należą lampy żarowe, w których strumień promieniowania powstaje w wyniku emisji cieplnej rozgrzanego żarnika. Mimo, że są one głównie wykorzystywane w zakresie pasma widzialnego, to jednak znaczna część emitowanej przez nie energii obejmuje zakres promieniowania IR. Wolframowa lampa żarowa może być wykorzystywana jako źródło promieniowania w zakresie od 350 do 2500 nm [102]. Lampa halogenowa jest udoskonaloną wersją lampy żarowej, w której dodatkowo znajduje się specjalny gaz szlachetny z niewielką ilością halogenu. Gaz ten powoduje regenerację włókna wolframowego, przez co znacznie wydłuża się jego żywotność [103].

Kamery stosowane w zakresie podczerwieni mogą być podzielone na wykorzystujące sensory termiczne lub kwantowe. Do pomiarów temperatury stosuje się różnego rodzaju detektory podczerwieni, których zasady działania polegają na wykorzystaniu następujących zjawisk [104]:

- efektu bolometrycznego polegającego na zmianie rezystancji detektora w zależności od temperatury,
- efektu termoelektrycznego, gdzie temperatura wywołuje zmianę siły termoelektrycznej,
- efektu piroelektrycznego polegającego na zmianie ładunku powierzchniowego detektora w zależności od temperatury fotoemisji pod wpływem działania docierającego promieniowania.

W elementach optyki stosowanych w systemach wizyjnych IR, należy zwrócić uwagę na istotną kwestię jaką są zakłócenia na rejestrowanych obrazach, powstające na skutek aberracji chromatycznej. Jeżeli układ optyczny nie jest odpowiednio skorygowany chromatycznie, promieniowanie z różnych części tego zakresu będzie ogniskowane w różnych punktach. W rezultacie długości fal znajdujące się bliżej jednej granicy pasma mogą być prawidłowo skupione na detektorze, natomiast pozostałe mogą powodować degradację ostrości i rozmycie obrazu. Z tego względu elementy optyki IR posiadają korekcję chromatyczną dzięki zastosowaniu różnego rodzaju materiałów w jednym układzie optycznym.

Systemy wizyjne, w których działaniu wykorzystywane jest promieniowanie podczerwone mogą zostać podzielone na pasywne i aktywne. Do pierwszej grupy układów obrazowania zaliczane są systemy pracujące w zakresie podczerwieni termalnej. W tego rodzaju rozwiązaniach, promieniowanie docierające do sensora kamery, pochodzi od obiektu inspekcji. Istotą termografii aktywnej jest badanie termicznej odpowiedzi materiałów w funkcji czasu na stymulację zewnętrznymi impulsami ciepła. Obserwowana próbka może być podgrzewana w wyniku [92]:

- absorpcji promieniowania wyemitowanego w jej kierunku,

- przepływu ładunku elektrycznego,
- oddziaływania prądów wirowych,
- oddziaływania ultradźwięków.

W zależności od sposobu stymulacji rozróżnia się kilka rodzajów termografii aktywnej [105]:

- impulsową (*ang. pulsed thermography*),
- modulacyjną (*ang. lock–in thermography*),
- impulsowo–fazową (*ang. pulsed–phase thermography*).

Termografia impulsowa polega na wyznaczeniu i analizie rozkładu temperatury na badanej powierzchni w czasie jej stygnięcia po uprzednim pobudzeniu impulsem cieplnym o określonym czasie trwania. Termografia modulacyjna (synchroniczna) określana jest również często terminem termografii lock–in [106]. W tej metodzie pobudzenie cieplne obiektu ma charakter okresowy, najczęściej sinusoidalny. Na podstawie znanej częstotliwości sygnału pobudzającego i zarejestrowanej odpowiedzi układu można wyznaczyć jej amplitudę i kąt przesunięcia fazowego. W metodzie termografii impulsowo–fazowej, powierzchnia badanego materiału jest nagrzewana impulsem cieplnym, który składa się z szeregu harmonicznych fal cieplnych. Długość trwania impulsu cieplnego determinuje zakres głębokości pod powierzchnią, na których ma być badany materiał. Częstotliwościowa analiza odpowiedzi obiektu na wymuszenie cieplne z zastosowaniem szybkiej transformaty Fouriera pozwala na wyznaczenie szeregu nowych obrazów parametrycznych przedstawiających wartości modułu i fazy dla różnych częstotliwości harmonicznych

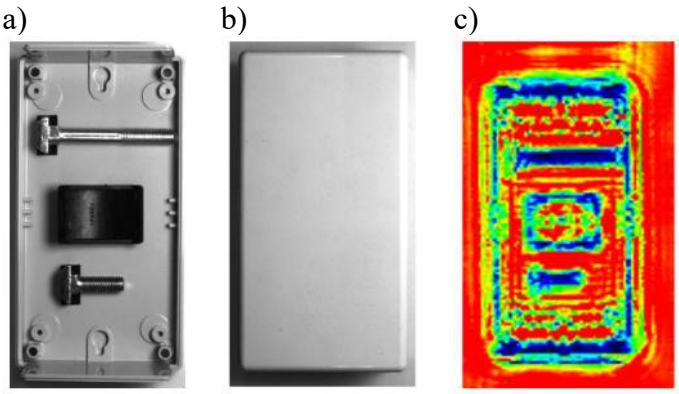
Promieniowanie terahercowe

Promieniowanie terahercowe obejmuje zakres fal elektromagnetycznych o częstotliwości od 0,1 do 10 THz, co odpowiada długości fali od 3mm do 30μm. Często wyróżniane jest dodatkowo pasmo sub–terahercowego, którego zakres wynosi od 0.1 do 1 THz [107]. Rozwój metod obrazowania terahercowego w ostatnich latach wynika przede wszystkim z opracowania zaawansowanych rozwiązań technicznych umożliwiających wytwarzanie kompaktowych źródeł promieniowania oraz detektorów pracujących w tym zakresie widma elektromagnetycznego. Postęp technologiczny stale rozszerza zakres zastosowań układów obrazowania terahercowego. Skuteczna implementacja takich systemów wymaga jednak pełnego zrozumienia procesu inspekcji oraz właściwości fizycznych badanego obiektu. Systemy terahercowe wychodzą obecnie z fazy badań laboratoryjnych i stopniowo znajdują zastosowanie w środowisku przemysłowym, choć ich wykorzystanie pozostaje nadal ograniczone, ze względu na wysokie wymagania dotyczące niezawodności i odporności na zakłócenia. Fale terahercowe charakteryzują się szeregiem unikalnych właściwości:

- bardzo słabe tłumienie w dielektrykach (tekstylia, papier, plastik, skóra, drewno),
- jest promieniowaniem niejonizującym,

- wysoka absorpcja przez substancje polarne (np. woda),
- złożone i indywidualne sygnatury spektralne materiałów,
- wysoką refleksyjnością metali.

Dzięki tym cechom obrazowanie terahercowe umożliwia przenikanie przez obiekty w celu obserwacji ich wewnętrznej struktury (Rys. 20).



Rys. 20. Obudowa z umieszczonymi elementami: a) wnętrze obudowy, b) widok po zakryciu, c) obraz sub–terahercowy zamkniętej obudowy [108]

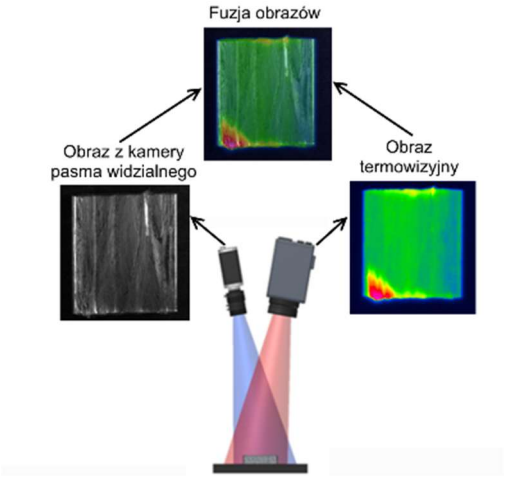
Oznacza to możliwość m.in. sprawdzania zawartości opakowań bez ich otwierania [109] czy obserwacji procesu gojenia ran bez potrzeby zdejmowania opatrunku [110]. Cechy promieniowania terahercowego umożliwiają potencjalne wykorzystanie tej technologii w wielu obszarach [111] m.in. w biomedycynie (diagnostyka chorób nowotworowych, identyfikacja schorzeń twardych tkanek zęba), w zakresie bezpieczeństwa publicznego i obronności (wykrywanie ukrytej broni), a także w kontroli jakości oraz diagnostyce technicznej.

Obrazowanie terahercowe, pomimo wielu zalet, charakteryzuje się jednak istotnymi ograniczeniami, zwłaszcza w kontekście niskiej rozdzielczości obrazowania i występowania zjawiska dyfrakcji [112]. Głębokość przenikania promieniowania terahercowego i czułość systemu inspekcji zależą od mocy źródła. W przypadku źródeł o małej mocy konieczne jest stosowanie zaawansowanych technologicznie sensorów o większej czułości. Co jest istotne, wraz ze zbliżaniem się do częstotliwości 1THz zmniejsza się moc źródeł [113]. Mimo postępu w pracach badawczych nad samymi detektorami THz, liczba dostępnych komercyjnie rozwiązań pozostaje skrajnie ograniczona. Główne bariery technologiczne hamujące szersze zastosowanie tej metody obrazowania koncentrują się wokół kilku kluczowych problemów. Po pierwsze, niewystarczająca rozdzielczość przestrzenna dostępnych obecnie sensorów THz stanowi zasadnicze ograniczenie, co jest dodatkowo pogłębione przez ich wysoki koszt, który jest bezpośrednio zależny od liczby elementów pomiarowych w matrycy. Poważnym wyzwaniem jest brak dedykowanych układów optycznych, co wymusza stosowanie układów bez obiektywów, w których pole widzenia i możliwości obserwacji są ograniczone rozmiarem samej matrycy. Wreszcie, niewystarczające parametry wydajnościowe kamer THz, takie jak niska liczba pikseli oraz ograniczony zakres częstotliwości, są wciąż nieadekwatne do wymagań stawianych w środowisku przemysłowym.

Wszystkie te czynniki jednoznacznie wskazują, że technologia ta jest wciąż na wczesnym etapie rozwoju i wymaga dalszych, intensywnych prac badawczo–rozwojowych, zanim będzie mogła znaleźć praktyczne i efektywne zastosowanie w przemysłowych systemach wizyjnych.

2.3. Metody fuzji obrazów

Fuzja obrazów (Rys. 21) to proces integrowania informacji pochodzących z wielu obrazów w celu zwiększenia niezawodności oraz uzyskania większej użyteczności w porównaniu z każdym z obrazów wejściowych.



Rys. 21. Hybrydowy system obrazowania [114]

Fuzja obrazów jest szczególnym przypadkiem fuzji danych [115]. Wykorzystanie fuzji danych umożliwia [116]:

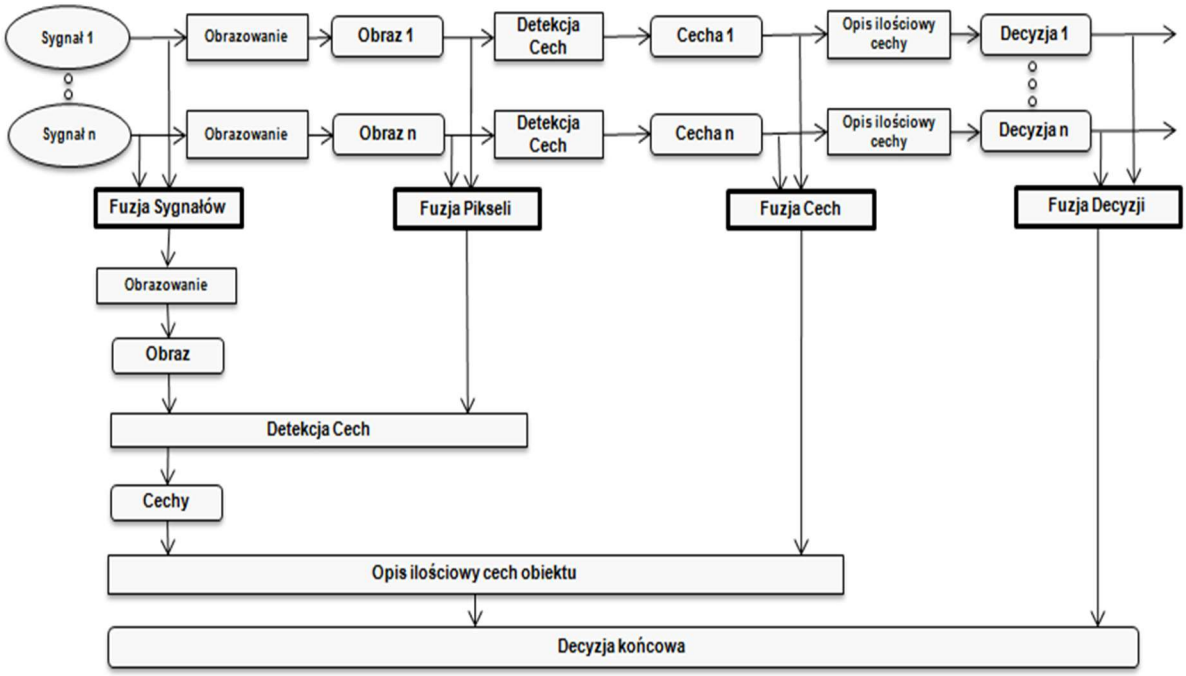
- większą szczegółowość reprezentacji informacji,
- zwiększenie dokładności pomiarów,
- eliminację zakłóceń i błędów pomiarowych,
- pełne obrazowanie zjawisk.

Fuzja danych z wielu źródeł wymaga uwzględnienia dodatkowych zagadnień związanych z ich przetwarzaniem i analizą, które nie występują w systemach wykorzystujących pojedyncze techniki pomiarowe [117]. Pierwsza grupa problemów dotyczy różnic w reprezentacji zarejestrowanych danych, do których możemy zaliczyć:

- niewspółmierność danych – różne sensory są czułe na odmienne zjawiska fizyczne, w związku z tym odpowiadają innym aspektom problemu i w konsekwencji wyrażone są często za pomocą niejednorodnych jednostek fizycznych,
- różnicę rozdzielczości – zarejestrowane zbiory danych mogą odpowiadać tym samych obszarom względem określonego układu współrzędnych jednak z bardzo różną rozdzielczością pomiarową,

- liczbę wymiarów – różne metody akwizycji danych mogą posiadać różne struktury zapisu np. macierze i tensory wyższego rzędu,
- rejestrację danych (*ang.* image registration) w tym samym układzie współrzędnych
- zakłócenia pomiarowe – zagadnienie dotyczy określenia jak łącznie zrównoważyć wpływ błędów pomiarowych pochodzących od różnych metod pomiarowych,
- częściowy brak danych dla poszczególnych metod obrazowania,
- konflikt, zaprzeczenie, niezgodność danych.

Kolejnym zagadnieniem jest wybór etapu przetwarzania, na którym zostanie przeprowadzona fuzja danych (Rys. 22). W wielu przypadkach korzystniejsze okazuje się łączenie cech wyodrębnionych z danych każdej techniki pomiarowej niż operowanie na sygnałach surowych. Natomiast przy całkowicie niewspółmiernych typach danych jedynym możliwym podejściem pozostaje fuzja wyników inspekcji (fuzja decyzji).



Rys. 22. Techniki fuzji obrazów [115]

Dominujący obecnie paradygmat w dziedzinie fuzji obrazów opiera się przede wszystkim na globalnym przetwarzaniu informacji wizualnej. W takim podejściu algorytmy fuzji operują na cechach zagregowanych, pozyskiwanych z całej obserwowanej sceny [118]. Choć metoda ta jest efektywna i pozwala na uzyskanie ogólnej reprezentacji obrazu, to jednak prowadzi do utracenia szczegółowych, lokalnych informacji, które mogłyby mieć kluczowe znaczenie dla precyzyjnego rozpoznawania i analizy obiektów docelowych. Tradycyjnie stosowane metody fuzji obrazów można podzielić na kilka głównych grup [119]:

- transformacje wieloskalowe (*ang. multiscale transform*) – techniki umożliwiające integrację informacji na różnych poziomach szczegółowości, wykorzystujące takie metody jak transformata falkowa,

- reprezentacje rzadkie (*ang. sparse representation*) – podejścia bazujące na modelach, w których obraz wyrażany jest jako kombinacja niewielkiej liczby elementów bazowych, co ułatwia ekstrakcję istotnych cech,
- metody oparte na sieciach neuronowych – rozwiązania wykorzystujące głębokie uczenie i zdolność modeli neuronowych do automatycznej ekstrakcji cech i ich fuzji,
- metody bazujące na wyrazistości (*ang. saliency–based methods*) – ukierunkowane na integrację obszarów najbardziej wyróżniających się w obrazie, czyli tych, które potencjalnie zawierają najważniejsze informacje,
- modele hybrydowe – łączące zalety różnych podejść w celu poprawy jakości fuzji.

Na tle powyższych metod stosunkowo rzadko spotyka się rozwiązania, które wprost koncentrują się na fuzji ukierunkowanej na detekcję lokalnych anomalii. Tego rodzaju systemy wykorzystują lokalną ekstrakcję cech oraz strategie fuzji oparte na segmentacji regionów lub wydzielaniu konkretnych obszarów zainteresowania (*ang. region–based fusion*). Dzięki temu możliwe jest zachowanie szczegółowych informacji dotyczących kluczowych elementów obrazu, co w wielu zastosowaniach takich jak inspekcja wizyjna, rozpoznawanie obiektów czy analiza obrazów medycznych stanowi istotną przewagę nad klasycznym podejściem globalnym.

2.4. Metody inspekcji optycznej opakowań zgrzewanych termicznie

Przemysłowe procesy zgrzewania termicznego są podatne na różnego rodzaju zakłócenia, w tym niewłaściwe ustawienie folii, zużycie elementów zgrzewających oraz zmienność materiałów. Każdy z tych czynników może prowadzić do powstawania defektów, które obniżają jakość produktu końcowego i generują dodatkowe koszty związane z reklamacjami oraz zużyciem surowców. Na podstawie przeprowadzonego przeglądu stanu techniki w obszarze systemów inspekcji przeznaczonych do kontroli jakości opakowań zgrzewanych termicznie, możliwe było wyodrębnienie dotychczas stosowanych metod optycznych wykorzystywanych w tego typu aplikacjach. Analiza literatury, patentów oraz dostępnych rozwiązań przemysłowych pozwala stwierdzić, że współczesne systemy inspekcji opakowań operują w różnych zakresach promieniowania elektromagnetycznego i wykorzystują odmienne techniki akwizycji obrazu, co umożliwia detekcję zróżnicowanych typów defektów. Zidentyfikowane metody optycznej inspekcji można sklasyfikować w następujące grupy:

- obrazowanie 2D i 3D w zakresie promieniowania widzialnego,
- obrazowanie w podczerwieni i termowizja,
- obrazowanie hiperspektralne.

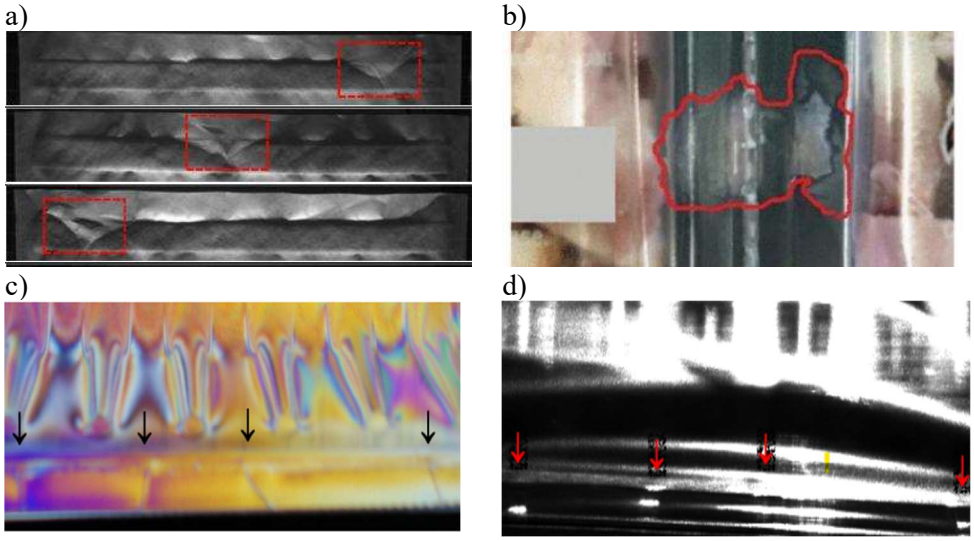
Jako kluczowe kierunki prac badawczo–rozwojowych w obszarze kontroli opakowań [12] eksperci wskazują rosnące znaczenie systemów wykorzystujących sztuczną inteligencję. Podkreślana jest również rola połączonej analizy wyników inspekcji z danymi procesowymi. Opracowane na tej podstawie systemy mogą być zastosowane do wspierania:

- decyzji dotyczących doboru materiałów i projektów opakowań,
- procesów modyfikacji sprzętowych maszyn pakujących,
- szkolenia operatorów,
- predykcyjne utrzymania ruchu maszyn.

W celu zapobiegania powstawaniu defektów w procesach pakowania jako istotne zagadnienia badawcze wskazuje się również metody hybrydowe, łączące różne technologie w celu zwiększenia niezawodności inspekcji oraz ograniczenia ryzyka błędnej klasyfikacji. Ponadto, ważne trendy obejmują modelowanie bliźniaków cyfrowych, które umożliwia wirtualne symulowanie procesów i ich optymalizację jeszcze przed wprowadzeniem fizycznych zmian. Jako jeden z kierunków prac wskazywana jest autonomiczna optymalizacja umożliwiająca wdrażanie usprawnień bez udziału człowieka, zwiększając szybkość reakcji na odchylenia procesowe.

Systemy wykorzystujące promieniowanie widzialne

Promieniowanie widzialne jako pierwsze stosowane w przemysłowych systemach inspekcji opakowań. Systemy tego rodzaju wykorzystywane są do detekcji weryfikacji nadruków [120] oraz wad powierzchniowych (Rys. 23a). Ich istotną zaletą jest możliwość zastosowania na wysokowydajnych liniach produkcyjnych. W przypadku zastosowania folii transparentnych możliwa jest również detekcja zanieczyszczeń w strefie zgrzewania [121]. W tego typu rozwiązaniach stosowany jest zarówno układ obrazowania odbiciowego jak również transmisyjnego (Rys. 23b). Ponadto zidentyfikowano metody detekcji wad powstających podczas procesu zgrzewania, które wykorzystują światło spolaryzowane (Rys. 23c) [122], rozpraszanie światła laserowego (Rys. 23d) oraz analizę danych 3D [123].

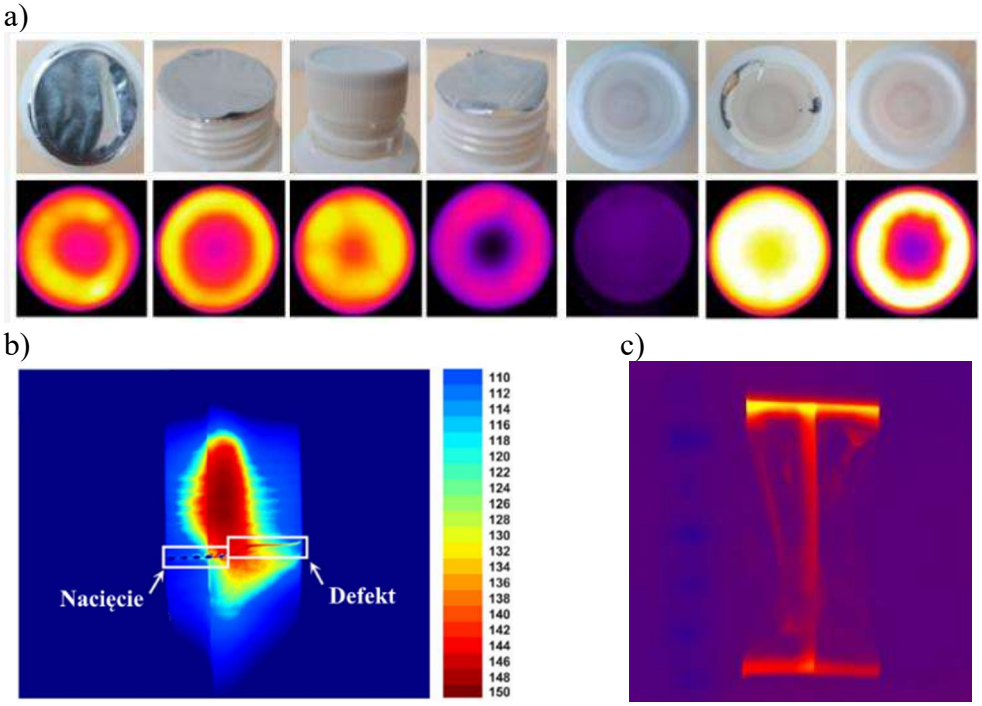


Rys. 23. Systemy inspekcji opakowań wykorzystujące promieniowanie widzialne a) kontrola powierzchni obszaru zgrzewania [124], b) detekcja zanieczyszczeń [121], c) światło spolaryzowane [125], d) rozpraszanie światła laserowego [125]

Systemy wykorzystujące metody obrazowania 3D stanowią obiecujący kierunek badań w automatyzacji inspekcji opakowań zgrzewanych termicznie. Jednak w przypadku bardzo cienkich warstw połączenia zgrzewanego oraz defektów mniejszych niż 0,2 mm kluczowy staje się dobór metody obrazowania dostosowanej do specyficznych wymagań zadania, ze szczególnym uwzględnieniem zależności między wymaganą rozdzielczością pomiaru, a wielkością pola obrazowania.

Systemy wykorzystujące promieniowanie podczerwone

W przypadku kontroli opakowań zgrzewanych termicznie, często stosowane są kamery termowizyjne umożliwiające detekcję anomalii [126], [127] w rozkładzie temperaturowym obszaru zgrzewania (Rys. 24). Ponadto ze względu na stosunkowo niską absorpcję promieniowania podczerwonego przez wiele materiałów stosowanych w opakowaniach oraz mniejszemu rozpraszaniu promieniowania na powierzchni obiektu wynikającemu z dłuższej długości fali, tego typu systemy mogą być stosowane do detekcji wad podpowierzchniowych [128]. Badania nieniszczące z wykorzystaniem termografii obejmują również symulacje przewodzenia ciepła lub wielowarstwowe analizy termiczne do szacowania parametrów materiałowych i zwiększenia interpretowalności wyników [129]. Podejmowano również próby zastosowania metod termografii aktywnej do inspekcji opakowań zgrzewanych termicznie [130].

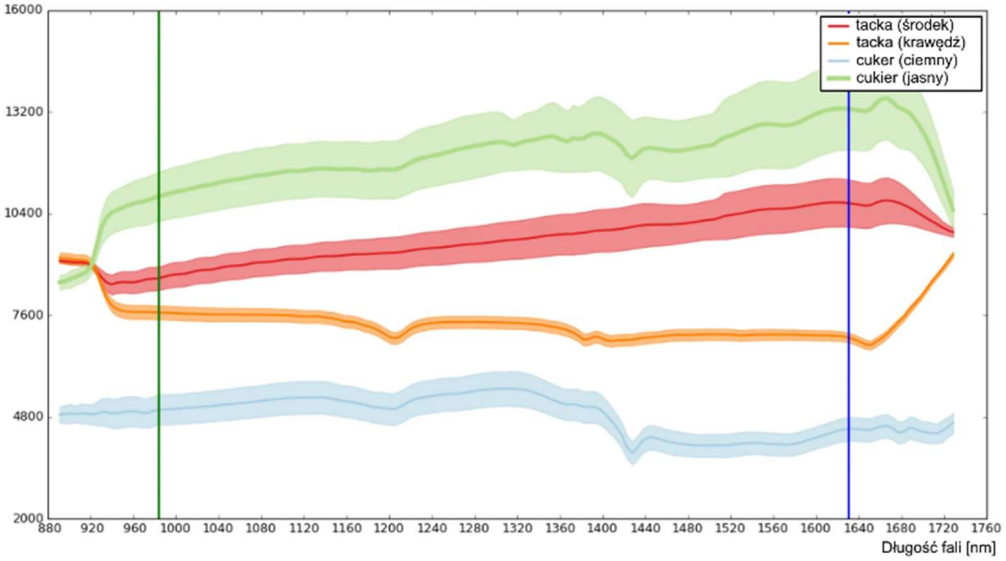


Rys. 24. Systemy inspekcji a) pojemników z folią aluminiową, a) opakowań z tworzywa sztucznego, c) opakowań foliowych [129], [131], [126]

Zastosowanie zaawansowanych metod analizy termogramów zwiększa skuteczność wykrywania ciał obcych w obszarze zgrzewania w porównaniu z analizą pojedynczych obrazów termicznych. Rozwiązanie to wymaga jednak rejestracji sekwencji termogramów, co wiąże się z koniecznością unieruchomienia obiektu na czas pozyskiwania profilu chłodzenia zgrzewu. Z tego względu zakres praktycznego zastosowania tej metody jest ograniczony przez uwarunkowania procesowe. Wyniki badań wskazują, że niezawodność detekcji oraz minimalny rozmiar wykrywanych ciał obcych w obszarze zgrzewania zależą w dużym stopniu od czasu, jaki upłynął od zakończenia procesu zgrzewania do momentu rejestracji termogramu. Dlatego prace badawcze prowadzone podczas opracowywania systemów inspekcji wykorzystujących promieniowanie termiczne powinny być realizowane w ściśle kontrolowanym reżimie czasowym. Prawidłowo zaprojektowany system kontroli zgrzewania termicznego pozwala nie tylko identyfikować wadliwe produkty, ale również optymalizować proces. Tego rodzaju rozwiązanie zostało z powodzeniem wdrożone do kontroli opakowań z indukcyjnym uszczelnieniem zakrętek [132]. Jednym z kluczowych usprawnień procesu była możliwość identyfikacji zmian w momencie dokręcania nakrętki na podstawie integralności i kompletności uszczelnienia.

Systemy wykorzystujące obrazowanie hiperspektralne

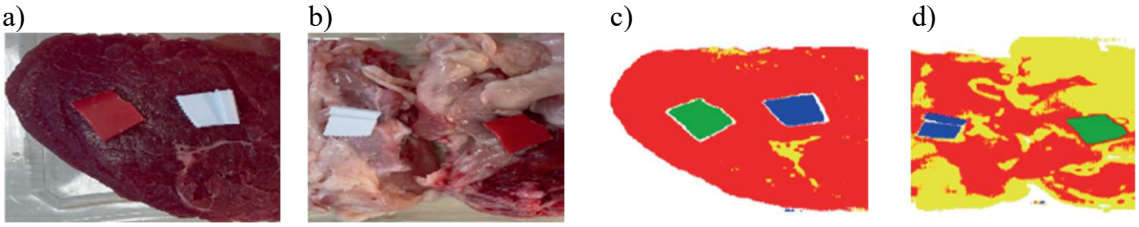
W przypadku kontroli opakowań zgrzewanych termicznie obrazowanie hiperspektralne umożliwia zwiększenie skuteczności detekcji zanieczyszczeń w strefie inspekcji [133], a także umożliwia ich klasyfikację poprzez analizę sygnatur spektralnych (Rys. 25).



Rys. 25. Przykładowe sygnatury spektralne z systemu kontroli opakowań [134]

Istotną zaletą przedstawionych rozwiązań jest możliwość efektywnej detekcji tłuszczy w strefie inspekcji, co jest znacznie utrudnione w przypadku klasycznych systemów wizyjnych wykorzystujących promieniowanie widzialne. Systemy hiperspektralne mogą być

wykorzystane do detekcji i klasyfikacji ciał obcych w produktach spożywczych (Rys. 26) jako uzupełnienie systemów X–ray [135].



Rys. 26. Detekcja ciał obcych w produktach spożywczych z wykorzystaniem kamery hiperspektralnej a) próbka I b) próbka II c) obraz HSI sklasyfikowany I d) obraz HSI sklasyfikowany II [135]

W tym przypadku zakres inspekcji ograniczony jest jedynie do detekcji obiektów, które znajdują się na powierzchni kontrolowanych wyrobów, co wynika z wysokiej absorpcji promieniowania optycznego. Do inspekcji opakowań transparentnych wykorzystywane są kamery z zakresu VIS–NIR (400÷1000 nm) z sensorami CMOS. Kontrola wyrobów pakowanych przy wykorzystaniu folii zadrukowanych wymagana natomiast zastosowania kamery SWIR (900÷1700 nm) z sensorami InGaAs. Tego typu rozwiązania umożliwiają inspekcję do kilku sztuk na sekundę inspekcji [133]. Do analizy zarejestrowanych danych wykorzystywane są zaawansowane metody obejmujące m.in. głębokie sieci neuronowe [134].

Podsumowanie

Kontrola jakości opakowań zgrzewanych termicznie obejmuje zastosowanie zarówno metod bezkontaktowych, jak i klasycznych badań niszczących. Ze względu na typowe wydajności linii produkcyjnych wynoszące do 60 szt./min, potencjalne zastosowanie technik NDTE (*ang. Nondestructive Testing and Evaluation*) musi opierać się na ich przystosowaniu do pracy w warunkach wysokiej przepustowości. Opracowanie i wdrożenie efektywnej kontroli jakości zgrzewów wymaga ponadto dogłębnego zrozumienia mechanizmów powstawania różnego rodzaju wad w danej aplikacji [136]. Do najczęściej stosowanych rozwiązań wykorzystujących promieniowanie optyczne należą:

- termografia pasywna i aktywna,
- systemy wizyjne wykorzystujące układy obrazowania odbiciowego i transmisyjnego,
- systemy obrazowania hiperspektralnego.

Historycznie jako pierwsze stosowane były systemy obrazowania w paśmie widzialnym. Jednym z najbardziej istotnych patentów w tym obszarze było rozwiązanie wykorzystujące jednocześnie analizę danych z dwóch kamer pasma widzialnego umieszczonych pod różnymi kątami względem opakowania [137]. Zastosowanie termografii do detekcji defektów zgrzewania w opakowaniach plastikowych zostało po raz pierwszy opisane w 2005 roku, a wynikająca z tego rozwiązania ochrona patentowa była utrzymywana przez kolejne 15 lat [138]. W ostatnich latach można zaobserwować wyraźny wzrost liczby przemysłowych systemów inspekcji opakowań wykorzystujących kamery termowizyjne [139], co wynika

m.in. z upowszechnienia kamer mikrobolometrycznych oraz obniżenia kosztów ich wdrożenia. Ponadto na liniach pakowania zastosowanie znalazły również kamery hiperspektralne, które umożliwiły kontrolę obszaru zgrzewania przez zadrukowane folie [140]. Inspekcja z wykorzystaniem tego rodzaju sensorów była łączona ze standardowymi systemami wizyjnymi w celu dostosowania do typu opakowania i specyficznych wad kontrolowanego produktu [141]. Nie są jednak opisane w tym przypadku zastosowane metody fuzji danych oraz korzyści z nich wynikające. Podejmowano, również próby zastosowania jednocześnie matrycowej kamery pasma widzialnego i kamery termowizyjnej do kontroli opakowań zgrzewanych laserowo [142]. Opisane próby laboratoryjne były prowadzone etapowo i w warunkach stacjonarnych, a analiza danych ograniczała się jedynie do fuzji decyzji pochodzących z dwóch systemów. Takie podejście nie spełnia jednak wymagań stawianych wysokowydajnym systemom inspekcji opakowań wdrażanym w środowisku przemysłowym.

Systemy hybrydowej inspekcji, łączące zalety różnych metod obrazowania, stanowią obecnie jeden z kluczowych kierunków rozwoju technologii kontroli jakości w przemyśle spożywczym. Podkreśla się szczególnie znaczenie algorytmów uczenia maszynowego, które umożliwiają efektywną ekstrakcję cech spektralnych i przestrzennych oraz zaawansowaną fuzję danych, prowadzącą do zwiększenia dokładności wyników inspekcji [143].

3. Cel i zakres pracy

Koncepcja gospodarki o obiegu zamkniętym (GOZ) zakłada poprawę efektywności wykorzystania zasobów poprzez wdrożenie strategii zrównoważonej i konkurencyjnej gospodarki. W przypadku przedsiębiorstw produkcyjnych, optymalizacja procesów, w celu osiągnięcia tych wytycznych, powinna być realizowana na każdym etapie cyklu życia produktu. W 2023 roku Ministerstwo Rozwoju i Technologii, wskazało rozwiązania technologiczne w obszarze GOZ, które umożliwiają kontrolę jakości produktów i monitoring cyklu życia produktu jako jeden z kluczowych kierunków badań w ramach Krajowych Inteligentnych Specjalizacji [144]. Priorytet ten jest spójny z aktualną strategią Sieci Badawczej Łukasiewicz, do której należy Instytut Technologii Eksploatacji – jednostka współpracująca przy realizacji pracy.

Zastosowanie zautomatyzowanych systemów optycznej inspekcji umożliwia wyeliminowanie czynnika ludzkiego związanego z brakiem powtarzalności, zmęczeniem i mniejszą sprawnością. Jest to szczególnie istotne w przypadku wysokowydajnej produkcji masowej, podczas której kontrola jakości wykonywana przez człowieka jest w znacznym stopniu ograniczona. W tym kontekście jedną z najbardziej wymagających gałęzi gospodarki pozostaje przemysł spożywczy [1]. Obecnie dla przedsiębiorstw produkcyjnych nie jest już wystarczające uzyskanie informacji jedynie o zgodności wyrobu z wymaganiami jakościowymi. Kluczowego znaczenia nabiera możliwość analizowania trendów procesowych, identyfikowania anomalii oraz wczesnego wykrywania odchyleń, które mogą wpływać na końcową jakość produktu, co umożliwia wcześniejszą reakcję, wdrożenie działań korygujących i doskonalących oraz stabilizację parametrów procesu. Istotnym zagadnieniem pozostaje jednak zapewnienie wysokiej jakości danych pochodzących z systemów inspekcji, które umożliwi klasyfikację różnego rodzaju wad.

Cel pracy

Celem pracy było opracowanie hybrydowej metody inspekcji opakowań zgrzewanych termicznie wykonanych z tworzyw sztucznych, realizowanej z wykorzystaniem wybranych pasm promieniowania optycznego oraz fuzji obrazów w celu uzyskania redundancji i komplementarności informacji o kontrolowanych wyrobach.

Zakres pracy

Pracę rozpoczyna rozdział pierwszy, w którym przedstawiono zarys historyczny rozwoju systemów optycznej inspekcji oraz ich znaczenie w zarządzaniu produkcją. W rozdziale tym omówiono również motywację oraz genezę podjętej tematyki badawczej, wynikającą z potrzeb rynkowych oraz strategii rozwoju obowiązującej w Łukasiewicz–ITeE.

Rozdział drugi zawiera przegląd literatury i analizę dostępnych rozwiązań dotyczących zagadnień omawianych w dysertacji. Opisano w nim zjawiska fizykalne występujące podczas inspekcji wizyjnej oraz przedstawiono usystematyzowaną klasyfikację metod optycznej inspekcji. Scharakteryzowane zostały również metody fuzji obrazów, które wykorzystywane są w systemach hybrydowych. Rozdział kończy przegląd zidentyfikowanych systemów optycznej inspekcji opakowań stosowanych w przemyśle.

W kolejnych rozdziałach przedstawiony został postęp prac badawczo–rozwojowych ukierunkowanych na opracowanie i wdrożenie hybrydowej metody optycznej inspekcji opakowań. Realizowane prace prowadzone były w oparciu o metodykę kolejnych poziomów dojrzałości technologicznej TRL (*ang. Technology Readiness Levels*), co umożliwiało systematyczne i kontrolowane przechodzenie od fazy koncepcyjnej do etapów bliższych wdrożeniu. W pierwszej kolejności opracowano koncepcję hybrydowego systemu inspekcji, która została zweryfikowana z wykorzystaniem metody symulacji cyfrowej układów obrazowania. Następnie wykonana została wersja modelowa systemu, umożliwiająca prowadzenie prac badawczych w laboratorium w symulowanych warunkach operacyjnych. Istotnym zagadnieniem było na tym etapie przygotowanie odpowiedniego wzorca i implementacja procedury kalibracji dostosowanej do specyfiki zastosowanych w systemie układów obrazowania. Ważnym elementem pracy była automatyzacja akwizycji danych poprzez zastosowanie manipulatora przemysłowego, co umożliwiło zapewnienie powtarzalności w procesie transportu próbek i akwizycji profili temperaturowych. W kolejnym kroku, na podstawie zarejestrowanych obrazów opracowana została dedykowana dla wysokowydajnych systemów inspekcji autorska metoda fuzji obrazów. Wygenerowane dzięki opracowanemu algorytmowi obrazy wynikowe procesu syntezy, zostały wykorzystane następnie do opracowania modelu klasyfikacji wad wykorzystującego głębokie sieci neuronowe. Opracowana baza danych zawierała obrazy wyrobów prawidłowo wykonanych oraz z zasymulowanymi wadami, które występują podczas procesu pakowania.

Rozdział piąty przedstawia eksperymenty ukierunkowane na opracowanie modelu przewidującego jakość opakowań, rozumianą jako wytrzymałość połączenia zgrzewanego na rozerwanie, na podstawie danych pozyskanych z hybrydowego systemu optycznej inspekcji. Prace obejmowały wybór kluczowych zmiennych oraz ocenę klasycznych modeli regresyjnych. Uzyskane rezultaty potwierdziły, że połączenie danych procesowych z wynikami inspekcji może stanowić uzupełnienie statystycznej kontroli wytrzymałości zgrzewu w postaci testów ciśnieniowych. Dzięki takiemu rozwiązaniu możliwe jest wcześniejsze wykrycie anomalii w procesie pakowania.

W dalszej części prac przedstawione zostały działania mające na celu pilotażowe wdrożenie proponowanego systemu inspekcji w zakładzie produkcyjnym z branży spożywczej. Przeprowadzone testy opracowanej metody inspekcji, potwierdziły skuteczność detekcji i klasyfikacji wad. Pracę kończy podsumowanie oraz wskazanie rozpoczętych kierunków dalszych badań, obejmujących zastosowanie metod uczenia maszynowego do predykcji jakości w przemysłowych procesach wytwarzania.

4. Metoda hybrydowej optycznej inspekcji opakowań

W ramach niniejszej pracy opracowana została hybrydowa metoda optycznej inspekcji opakowań zgrzewanych termicznie. Przyjęte podejście badawcze uwzględniało interdyscyplinarny charakter zagadnienia obejmujący zadania z zakresu mechaniki, elektroniki, optyki, optoelektroniki i informatyki. Realizacja prac badawczych wymagała przeprowadzenia szeregu złożonych prac inżynierskich. Obejmowały one między innymi: projektowanie i budowę dedykowanych stanowisk eksperymentalnych, dobór oraz integrację komponentów optycznych i elektronicznych, a także opracowanie oprogramowania umożliwiającego akwizycję, przetwarzanie oraz analizę obrazów.

W pierwszym etapie opracowane zostały ogólne założenia w zakresie cech funkcjonalnych i parametrów technicznych systemu inspekcji. W tym celu nawiązana została współpraca z firmą produkcyjną z branży spożywczej. Podczas wizji lokalnej w zakładzie produkcyjnym określone zostały wymagane parametry techniczne. Wykonano analizę norm bezpieczeństwa urządzeń stosowanych w przemyśle spożywczym oraz wewnętrznych wymagań zakładowych. Dla zapewnienia zgodności z normami bezpieczeństwa obowiązującymi w przemyśle spożywczym należy stosować odpowiednie materiały części maszyn, które mają kontakt z żywnością. W tym celu wykorzystywane są m.in. obudowy ze stali nierdzewnej oraz tworzywa sztuczne z odpowiednimi atestami. Ponadto, zgodnie z normą PN–EN 1672 konieczne jest zapewnienie łatwego dostępu do wszelkich części maszyn w celu umożliwienia ich częstego i dokładnego czyszczenia. Stosowane są w tym celu silne środki chemiczne oraz mycie wysokociśnieniowe. Z tego względu opracowana konstrukcja powinna charakteryzować się klasą szczelności minimum IP67, zalecane są jednak rozwiązania z klasą IP69K.

Zgodnie z przyjętymi założeniami ustalone zostały warunki brzegowe dla systemu inspekcji:

- zakres przedmiotowy: kontrola jakości tacek oraz pojemników wykonanych z tworzyw sztucznych, zamykanych przy użyciu transparentnych folii zgrzewalnych,
- wymiary maksymalne opakowań: ½ GN (*ang. Gastro Norm*) 325 × 265 x 100 mm,
- typ opakowań: jedno lub wielokomorowe, barwa czarna,
- wydajność operacyjna: maksymalna częstotliwość inspekcji do 2 szt./s,
- kontrola wyrobów transportowanych z prędkością wynoszącą do 400 mm/s, bez możliwości zatrzymania linii produkcyjnej na czas inspekcji,
- detekcja wad o powierzchni powyżej 1 mm^2,
- rezultat inspekcji w postaci binarnej w celu integracji z wyrzutnikiem.

Ponadto system powinien umożliwiać klasyfikację defektów oraz umożliwiać analizę profilu temperaturowego obszaru zgrzewania w zakresie od 0 do 150 C˚. Na podstawie konsultacji z pracownikami zakładu produkcyjnego oraz przeglądu literatury, do dalszych prac projektowych przyjęto listę wad krytycznych [145], są to:

- zagniecenia oraz złe pozycjonowanie folii,
- zanieczyszczenie lub zatłuszczenie strefy zgrzewu,

- zmarszczki, które spowodowane są przez nierównomierne napięcie folii na całej jej szerokości,
- brak lub słaby zgrzew, spowodowany zbyt niską temperaturą, za krótkim czasem zgrzewania lub zbyt małą siłą docisku.

Jako istotne zagadnienie wskazano także minimalizację wymiarów zewnętrznych urządzenia, a także przystosowanie do pracy w niskiej temperaturze otoczenia (od 0 do 7˚C).

4.1. Opracowanie koncepcji rozwiązania

Zgodnie z metodyką projektowania innowacyjnych systemów optomechatronicznych [146], w przypadku złożonych struktur, do wyboru rozwiązania, stosowane powinny być metody wspomagające podejmowanie decyzji. Najczęściej wykorzystywane w tym celu metody obejmują:

- wielokryterialne metody podejmowania decyzji,
- drzewa decyzyjne,
- analizy przyczyn i skutków wad FMEA (*ang. Failure Mode and Effects Analysis*),
- analizy ryzyka.

Do opracowania koncepcji systemu hybrydowej optycznej inspekcji opakowań, wykorzystano wielokryterialną macierz decyzyjną opracowaną zgodnie z metodą Pugha [147]. Metoda ta upraszcza proces podejmowania decyzji poprzez umożliwienie systematycznej oceny, co czyni ją cennym narzędziem w projektowaniu. Zastosowanie tego podejścia wspiera głębsze zrozumienie wymagań i problemów projektowych, ułatwia wizualizację zależności między rozwiązaniami oraz nie wymaga dużej ilości danych.

W pierwszym etapie opracowania koncepcji określono kryteria wyboru i przypisano im odpowiednie wagi. Następnie przeprowadzono wstępną selekcję metod obrazowania, które mogły spełnić zdefiniowane wymagania. Alternatywne koncepcje porównano z wariantem bazowym zgodnie z zasadami metody Pugha, oceniając je względem przyjętych kryteriów. Na podstawie uzyskanego rankingu wytypowano rozwiązanie uznane za najbardziej korzystne.

Kryteria wyboru i wagi

Podstawowym celem opracowania systemu inspekcji jest skuteczna detekcja wad wyrobów, które uniemożliwiają jego dalszą eksploatację. Z tego względu za kluczowe kryteria uznano zdolność systemu do wykrywania poszczególnych kategorii defektów:

- K_1 – detekcja wad powierzchniowych w postaci zagnieceń, zmarszczek,
- K_2 – detekcja wad pod powierzchnią folii transparentnej, w tym zanieczyszczeń,
- K_3 – detekcja wady w postaci braku lub słabego zgrzewu.

Kolejne przyjęte kryteria dotyczyły zagadnienia jakości obrazów, które mają istotny wpływ na powtarzalność rezultatów inspekcji:

- K_4 – jednorodność natężenia promieniowania EM w całym obszarze inspekcji,
- K_5 – rozmycie obrazu wynikające z zastosowanej technologii akwizycji obrazów.

W dalszej kolejności przyjęto kryteria dodatkowe funkcjonalne, rozszerzające możliwości analityczne systemu lub jego zakres stosowalności:

- K_6 – detekcja wad pod powierzchnią folii zadrukowanej, w tym zanieczyszczeń,
- K_7 – możliwość rejestracji profilu temperaturowego zgrzewu, podczas ruchu,
- K_8 – klasyfikacja różnego rodzaju wad, w tym rozpoznawanie substancji.

Na końcu określone zostały kryteria użytkowe, związane z procesem wdrożenia:

- K_9 – dojrzałość wdrożeniowa i przystosowanie do przemysłu spożywczego,
- K_{10} – obsługa systemu, w tym częstotliwość powtórnej kalibracji,
- K_{11} – skalowalność systemu. Możliwość adaptacji, rozbudowy lub modyfikacji,
- K_{12} – koszt wytworzenia kolejnych egzemplarzy w przypadku sprzedaży seryjnej.

W kolejnym etapie kryteria poddane zostały procesowi nadawania wag w skali od 1 do 5. Parametry decyzyjne związane z detekcją wad otrzymały najwyższą rangę ($K_1 \div K_3$). Kryteriom związanym z jakością obrazów (K_4, K_5) przypisana została waga 4. Wskaźniki określające zwiększenie możliwości analitycznych i zakresu wykorzystania ($K_6 \div K_8$) otrzymały poziom 3. Ta sama waga przypisana została aspektowi przystosowania do warunków przemysłowych. Za najmniej istotne w analizie uznano poziom trudności obsługi (waga 2) oraz skalowalność systemu (waga 1). Ze względu na główny cel prowadzonych prac, najwyższa wartość wagi przypisana została do kosztu wytworzenia sytemu – K_{12}.

Selekcja układów obrazowania

W celu ograniczenia liczby możliwych konfiguracji, z dalszej analizy wyeliminowane zostały metody obrazowania nie spełniające podstawowych warunków brzegowych systemu inspekcji. W metodach obrazowania wykorzystujących oświetlenie aktywne, przyjęto założenie, że układ oświetlenia zostanie opracowany w dalszym etapie prac, zapewniając najwyższą możliwą jakość rejestrowanych obrazów dla docelowej aplikacji. Ze względu na ograniczoną rozdzielczość obrazowania oraz ograniczoną dostępność odpowiedniej aparatury, systemy terahercowe nie zostały uwzględnione w analizie. Rodzaj zastosowanego opakowania i jego barwa uniemożliwia również zastosowanie układów obrazowania transmisyjnego w pozostałych zakresach spektrum elektromagnetycznego. Ze względu na przyjęty zakres pomiaru temperatury, odrzucone zostały kamery termowizyjne z zakresu podczerwieni krótkofalowej. Ostatecznie, do zbudowania macierzy Pugha wykorzystano siedem alternatywnych wariantów układów unimodalnych obrazowania oraz ich wybrane kombinacje:

- W_1 – kamera matrycowa pasma widzialnego, z dedykowanym układem oświetlenia,
- W_2 – kamera matrycowa UV, z dedykowanym układem oświetlenia,

- W_3 – kamera liniowa VIS, z dedykowanym układem oświetlenia liniowego,
- W_4 – kamera termowizyjna LWIR,
- W_5 – kamera termowizyjna MWIR,
- W_6 – kamera hiperspektralna VIS/NIR, z dedykowanym układem oświetlenia,
- W_7 – kamera hiperspektralna SWIR, z dedykowanym układem oświetlenia,
- W_8 – połączenie wariantów W_1 i W_4,
- W_9 – połączenie wariantów W_1 i W_6,
- W_{10} – połączenie wariantów W_1 i W_7,
- W_{11} – połączenie wariantów W_3 i W_4,
- W_{12} – połączenie wariantów W_3 i W_6,
- W_{13} – połączenie wariantów W_3 i W_7.

Klasyczny układ obrazowania z kamerą matrycową VIS, który najczęściej stosowany jest w systemach kontroli opakowań, został przyjęty jako koncepcja bazowa W_1.

Ranking ogólny koncepcji systemu inspekcji

Zgodnie z metodą Pugha wariant bazowy, oznaczany jako W_1, pełni funkcję punktu odniesienia dla całej analizy. W macierzy decyzyjnej jego ocena jest zapisywana symbolem „S", co oznacza, że stanowi on standard porównawczy. Pozostałe koncepcje projektowe są następnie oceniane względem wariantu bazowego dla każdego z przyjętych kryteriów. W zastosowanej procedurze ocena układów hybrydowych również jest wykonywana w odniesieniu do koncepcji bazowej. W celu większego zróżnicowania, ocena porównawcza została przedstawiona za pomocą następujących kategorii [148]:

- „+" – wariant korzystniej oceniany dla danego kryterium,
- „++" – wariant zdecydowanie korzystniej oceniany dla danego kryterium,
- „S" – wariant oceniany na poziomie porównywalnym do koncepcji bazowej,
- „–„ – wariant oceniany mniej korzystnie od koncepcji bazowej,
- „– –„ – wariant oceniany zdecydowanie mniej korzystnie od koncepcji bazowe.

W tabeli 4 przedstawione zostały oceny analizowanych wariantów projektowych systemu inspekcji opakowań zgrzewanych termicznie. Warto zaznaczyć, że wybór pomiędzy układami wykorzystującymi kamery termowizyjne LWIR oraz MWIR jest zależny, głównie od przypisanego poziomu istotności do kryteriów kosztu i jakości obrazów. Jako wariant najbardziej korzystny pod względem przyjętych kryteriów została oceniona metoda hybrydowa (W_{11}) wykorzystująca kamerę liniową pasma widzialnego oraz kamerę termowizyjną LWIR.

Tabela 4. Macierz wyboru koncepcji

			Koncepcje projektowe												
		Waga	W_1	W_2	W_3	W_4	W_5	W_6	W_7	W_8	W_9	W_{10}	W_{11}	W_{12}	W_{13}
Kryterium wyboru	K_1	5	S	+	S	–	–	S	–	S	S	S	S	S	S
	K_2	5	S	–	S	S	S	S	S	S	S	S	S	S	S
	K_3	5	S	S	S	S	S	S	S	S	S	S	S	S	S
	K_4	4	S	–	+	+	+	+	+	S	S	S	+	+	+
	K_5	4	S	S	S	–	S	S	S	S	S	S	S	S	S
	K_6	3	S	–	S	++	++	+	++	++	+	++	++	++	++
	K_7	3	S	S	S	+	+	S	S	+	S	S	+	S	S
	K_8	3	S	S	S	S	S	+	+	+	+	++	+	+	++
	K_9	3	S	–	S	S	S	S	S	S	S	S	S	S	S
	K_{10}	2	S	S	S	S	S	–	–	S	–	–	S	–	–
	K_{11}	1	S	S	+	S	S	+	+	S	S	S	S	S	S
	K_{12}	5	S	–	S	S	—	—	—	–	—	—	–	—	—
Suma „+”			1	2	4	4	4	5	4	2	4	5	4	5	
Suma „–„			5	0	2	3	3	4	1	3	3	1	3	3	
Wynik całkowity			–4	2	2	1	1	1	3	–1	1	4	1	2	
Wynik ważony			–15	5	4	–2	–1	–3	7	–6	0	11	1	4	

Proces projektowania unikatowych, innowacyjnych urządzeń i aparatury przebiega zarówno sekwencyjnie, jak i iteracyjnie [146]. Na każdym etapie projektu przeprowadzana jest jego weryfikacja, a w przypadku niespełnienia założonych wymagań możliwy jest powrót do wcześniejszych koncepcji i kontynuacja prac rozwojowych. Przygotowana w pierwszym etapie macierz koncepcji Pugha umożliwia w takim przypadku wykorzystanie kolejnego wariantu, zgodnie z opracowanym rankingiem.

4.2. Modelowanie układów obrazowania

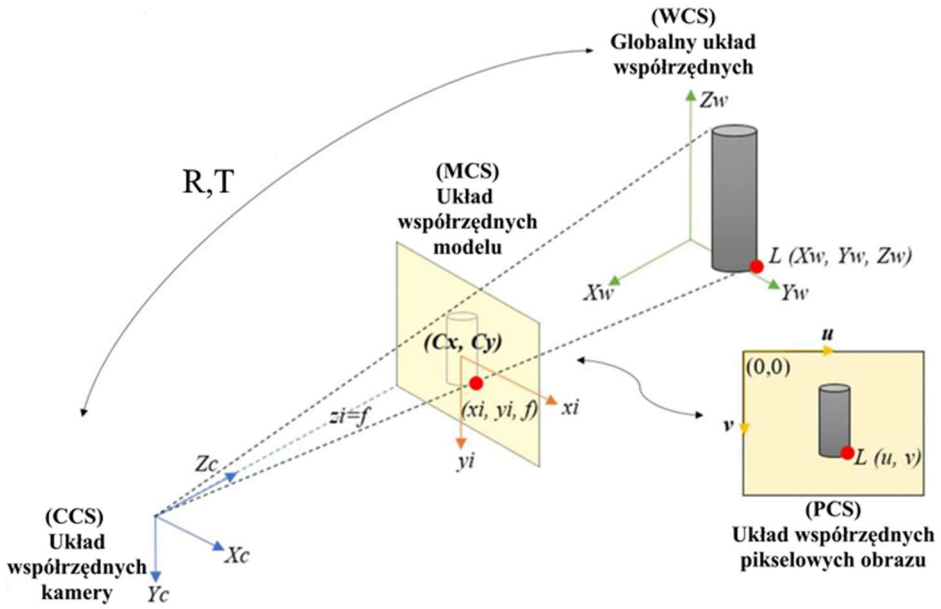
Zgodnie z metodyką projektowania innowacyjnych systemów optomechatronicznych przedstawioną w pracy, modelowanie powinno być ukierunkowane na wytworzenie modeli fizycznych umożliwiających zademonstrowanie wybranych komponentów systemu i przeprowadzenie symulacji, przy ustalonych warunkach brzegowych i początkowych. Model symulacyjny umożliwia natomiast odwzorowanie funkcjonalności projektowanego modułu lub zespołu modułów zgodnie z przyjętymi kryteriami. Podczas badania unikatowych systemów dedykowanych do kontroli jakości wyrobów jako istotny etap wskazywana jest zarówno weryfikacja algorytmów inspekcji jak również struktury torów wizyjnych [149]. Na etapie projektowania wykorzystywane są w tym celu wirtualne modele. W zależności od stopnia ogólności, badania prototypowych urządzeń technicznych, mogą być wykonywane z zastosowaniem symulacji cyfrowej modelu matematycznego lub symulacji modelu wirtualnego:

- model matematyczny stanowi abstrakcyjny opis rozpatrywanego systemu i jest odwzorowaniem symbolicznym wykorzystującym reprezentację graficzną lub analityczną do przedstawienia struktury z uwzględnieniem koniecznych uproszczeń,
- model wirtualny stanowi opracowany w środowisku CAD obiekt wykorzystywany do badań i weryfikacji prowadzonej na etapie projektowania. Szczegółowość modelu geometrycznego zależy od stopnia zaawansowania projektu, specyfiki wykorzystywanego systemu komputerowego oraz celu symulacji.

W procesie modelowania i projektowania systemów optomechatronicznych wykorzystywane są metody komputerowe obejmujące [146]:

- programy grupy CAX,
- specjalistyczne programy do projektowania układów obrazowania,
- środowiska do wykonywania obliczeń naukowych i inżynierskich.

W dziedzinie widzenia komputerowego (*ang. computer vision*) najczęściej stosuje się model kamery otworkowej (*ang. pinhole camera*), który umożliwia liniowe odwzorowanie trójwymiarowej sceny na dwuwymiarową płaszczyznę obrazu [150] (Rys. 27).



Rys. 27. Rzutowanie perspektywiczne w modelu kamery otworkowej [150]

Parametry wykorzystywane w tym modelu można podzielić na wewnętrzne [151]:

- f – efektywna długość ogniskowej, która jest określona przez dystans pomiędzy płaszczyzną obrazowania i punktem głównym układu optycznego,
- k_1, k_2 – zniekształcenia optyczne radialne,
- s_x – współczynnik skali.

Parametry zewnętrzne kamery wyrażone są przez macierz rotacji $\boldsymbol{R}$ oraz wektor translacji $\boldsymbol{T}$ i umożliwiają przekształcenie współrzędnych z układu WCS (*ang. World Coordinate System*)

na współrzędne pikselowe PCS (*ang. Pixel Coordinate System*). Transformacja pomiędzy współrzędnymi $\boldsymbol{v_w}$ (x_w, y_w, z_w) globalnego układu współrzędnych, a współrzędnymi układu CSS (*ang. Camera Coordinate System*) kamery $\boldsymbol{v_c}$ (x_c, y_c, z_c) jest możliwy za pomocą wzoru (10):

$$\boldsymbol{v_c} = \boldsymbol{R}\boldsymbol{v_w} + \boldsymbol{T} \tag{10}$$

Wykorzystując projekcję perspektywiczną, możliwe jest przekształcenie współrzędnych piksela na obrazie bez zniekształceń (u,v) do układu współrzędnych 3D za pomocą zależności (11):

$$u = \frac{fx_c}{z_c}$$

$$v = \frac{fy_c}{z_c} \tag{11}$$

W modelu uwzględniającym zniekształcenia optyczne obiektywu konieczne jest wprowadzenie do wzoru dodatkowych współczynników dystorsji (D_x, D_y), które opisują radialne przemieszczenia położeń pikseli wynikające z deformacji obrazu. Zależność tą można przedstawić za pomocą wzoru (12).

$$u_d = u + D_x$$

$$v_d = v + D_y \tag{12}$$

gdzie:

$$D_x = u_d(k_1 r + k_2 r^4)$$

$$D_y = v_d(k_1 r + k_2 r^4)$$

$$r = \sqrt{u_d^2 + v_d^2}$$

Rzeczywiste współrzędne obrazu (u_f, v_f) po uwzględnieniu niepewności współczynnika skali otrzymuje się z zależności (13):

$$u_f = \frac{s_x u_d}{d_x''} + c_x$$

$$v_f = \frac{v_d}{d_y'} + c_y \tag{13}$$

gdzie:

u_f, v_f – numer wiersza i kolumny na obrazie,

$d_x'' = d_x' \cdot N_{c_x}/N_{c_y}$,

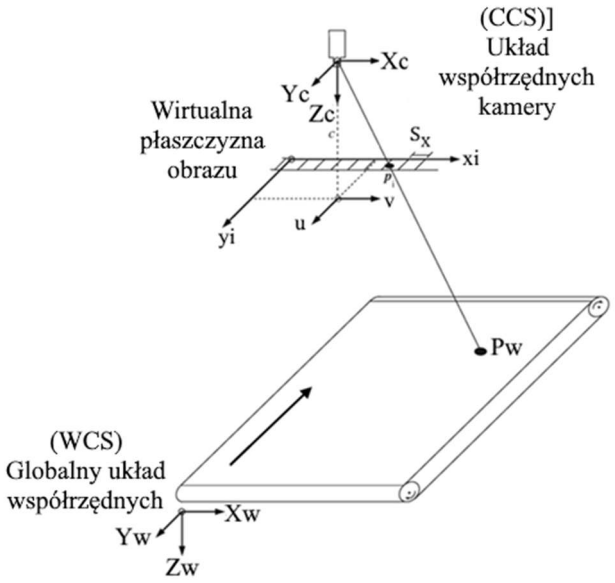
d_x' – odległość między sąsiednimi elementami sensora w kierunku *x*,

d_y' – odległość między sąsiednimi elementami sensora w kierunku *y*,

N_{c_x} – liczba elementów sensora w kierunku *x*,

N_{c_y} – liczba elementów sensora w kierunku *y*.

W przypadku modelu kamery liniowej zakłada się że obiekt porusza się względem kamery ruchem jednostajnym prostoliniowym (Rys. 28), a sensor zamodelowany jest jako pojedyncza linia wirtualnej kamery macierzowej [152].



Rys. 28. Model kamery liniowej [152].

Model kamery otworkowej, uwzględniający korekcję zniekształceń, umożliwia poprawne odwzorowanie geometryczne. Jednak zastosowanie bardziej zaawansowanych modeli kamer takich jak model oparty na promieniach (*ang. ray–based*) czy model kamery generycznej (*ang. generic–camera*) może prowadzić do uzyskania bardziej dokładnych rezultatów [153]. Jak wynika z przeprowadzonych badań tego rodzaju symulacje mogą być wykorzystywane do optymalizacji układów obrazowania systemów kontroli jakości wytwarzania [154]. Wygenerowane obrazy syntetyczne, obejmujące różne przykłady wad, umożliwiają opracowanie modelowych algorytmów analizy obrazów już na wczesnym etapie projektowania systemu inspekcji, a także walidację opracowanych koncepcji.

Wyznaczenie podstawowych parametrów systemu inspekcji

Podstawowym parametrem systemu wizyjnego, który definiuje wybór odpowiedniej kamery i obiektywu jest wielkość pola obserwacji FOV (*ang. Field of View*), która może być wyznaczona z wzoru (14) [68]:

$$FOV = D + T + O + P \tag{14}$$

gdzie:

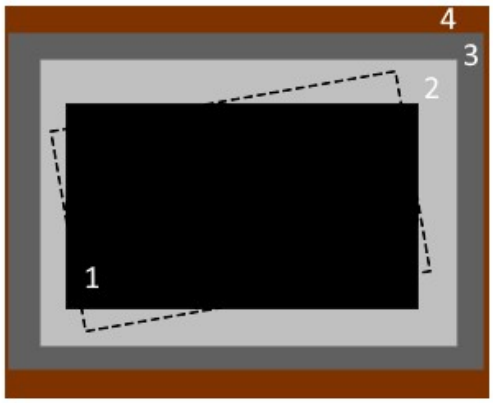
D – maksymalny wymiar obiektu,

T – tolerancja pozycjonowania,

O – offset względem krawędzi zewnętrznych obiektu inspekcji,

P – dostosowanie do proporcji sensora kamery.

Na rysunku 29 kolorem czarnym oznaczony został przykładowy obiekt inspekcji. Obszar wymaganej tolerancji pozycjonowania (kolor jasno–szary) zależy zarówno od zastosowanych rozwiązań konstrukcyjnych jak również czujnika detekcji obiektu w strefie inspekcji, który wyzwala akwizycję obrazu. Częstym założeniem jest przyjęcie poziomu tolerancji pozycjonowania równej 10% wartości wymiaru obiektu inspekcji [155]. Ponadto należy uwzględnić offset wymagany dla algorytmów wyznaczających pozycję opakowania, a także dostosować FOV do formatu zastosowanego sensora. Dla omawianego przypadku pozycjonowanie w osi prostopadłej do ruchu obiektu zapewnione jest przez boczne bandy ograniczające możliwość przesunięcia i obrotu. W kierunku wzdłuż osi transportera założono powtarzalność wyzwolenia akwizycji kamery przy zastosowaniu standardowego czujnika odbiciowego.



Rys. 29. Wyznaczenie minimalnego pola obserwacji FOV: 1 – maksymalne wymiary obiektu inspekcji, 2 – obszar po uwzględnieniu tolerancji pozycjonowania, 3 – obszar po uwzględnieniu offsetu algorytmu inspekcji, 4 – obszar po dostosowaniu do formatu sensora

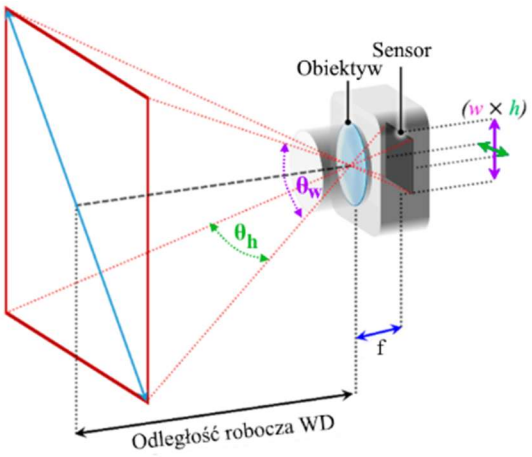
Zestawienie wszystkich parametrów mających wpływ na wielkość FOV zostało przedstawione w tabeli 5.

Tabela 5. Parametry systemu inspekcji do wyznaczenia FOV

Parametr	D [mm]	T [%]	O [mm]	P_L [mm]	P_A [mm]	FOV_L [mm]	FOV_A [mm]
Oś horyzontalna	325	5	5	0	31,42	346,25	377,66
Oś wertykalna	265	5	5	0	0	283,25	283,25

W przypadku zastosowania kamery liniowej nie jest wymagane dostosowanie proporcji sensora (P_L=0). Liczba zarejestrowanych linii obrazu, która jest rejestrowana przez kamerę, może być ustawiona w oprogramowaniu w taki sposób, aby zapewnić pożądany format obrazu. Wykorzystanie klasycznego sensora w formacie 4:3 powoduje konieczność zwiększenia FOV w osi horyzontalnej o wartość P_A=31,42 mm.

Kolejnym kluczowym parametrem systemu jest kątowe pole widzenia (Rys. 30) AFOV (*ang. Angular Field of View*) w osi horyzontalnej (θ_h) i wertykalnej (θ_w), które określa zależność między rozmiarem sensora, a ogniskową obiektywu, determinując tym samym zakres przestrzeni obserwowanej przez kamerę [156].



Rys. 30. Kątowe pole obserwacji systemu wizyjnego [157]

W zależności od zakresu kąta obserwacji obiektywy można sklasyfikować na kilka kategorii od szerokokątnych obiektywów, aż do teleobiektywów (Tab. 6). W przypadku, gdy nie ma ograniczeń mechanicznych dotyczących odległości roboczej WD (*ang. Working Distance*) zalecane jest stosowanie obiektywów o standardowych kątach obserwacji [158]. Standardowy AFOV minimalizuje ryzyko wystąpienia zniekształceń perspektywicznych typowych dla obiektywów szerokokątnych, a jednocześnie nie wymaga dużych odległości roboczych charakterystycznych dla teleobiektywów. Ponadto ma to szczególne znaczenie w zadaniach wysokowydajnej inspekcji, gdzie pożądana jest niska wartość przysłony $f_{\#}$, co umożliwia ograniczenie zjawiska rozmycia rejestrowanych obrazów, ale jednocześnie powoduje ograniczenie zakresu głębi ostrości [68].

Tabela 6. Klasyfikacja obiektywów w zależności od kąta obserwacji [158]

Rodzaj obiektywu	Zakres kąta obserwacji θ [˚]	Maksymalna przysłona $f_{\#}$ [–]	Ogniskowa obiektywu f [mm]
Rybie oko (*ang. fish eye*)	180–220	2.8	6–10
Quasi rybie oko (*ang. quasi fish eye*)	100–180	3.5	10–16
Ekstremalnie szerokokątny (*ang. extreme wide–angle*)	100–120	3.5	13–18
Bardzo szerokokątny (*ang. very wide–angle*)	84–94	2.0	20–24
Szerokokątny (*ang. wide–angle*)	62–75	1.4	28–35
Standardowy obiektyw	43–56	1.0	40–55
Krótki teleobiektyw (*ang. short telephoto*)	23–37	1.4	75–105
Średni teleobiektyw (*ang. medium telephoto*)	12–21	2.0	120–200
Długi teleobiektyw (*ang. long telephoto*)	5–8	2.8	300–500
Długi teleobiektyw (*ang. extreme telephoto*)	2–4	5.6	600–1200

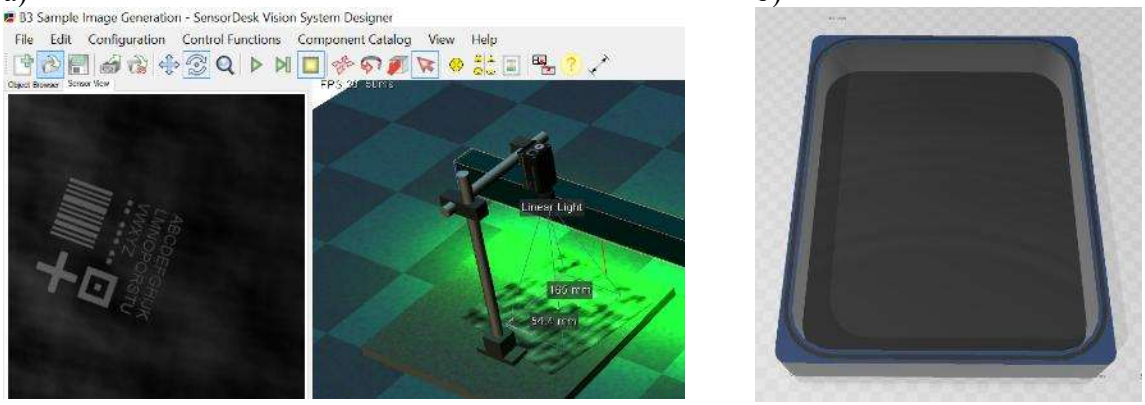
Zgodnie z warunkami brzegowymi przyjętymi dla opracowywanego systemu, w badaniach symulacyjnych zastosowano zakres kątowego pola widzenia AFOV od 43° do 56°, odpowiadający charakterystyce obiektywów standardowych.

Wykorzystanie obrazów syntetycznych w procesie modelowania

W celu weryfikacji opracowanej koncepcji systemu inspekcji opakowań zgrzewanych termicznie wykorzystane zostało specjalistyczne oprogramowanie Vision System Designer, opracowane przez firmę SensorDesk [159]. Rozwiązanie to umożliwia zaawansowane symulacje cyfrowe przemysłowych systemów kontroli wizyjnej (Rys. 31a). Oprogramowanie zawiera modele oświetlenia, obiektywów i kamer, które można skonfigurować względem obiektu docelowego, a także generować obrazy syntetyczne w czasie rzeczywistym.

Podczas procesu modelowania hybrydowego systemu inspekcji wykorzystano uproszczony model 3D STL przedstawiający geometrię opakowania. Warstwę folii odwzorowano natomiast jako maskę o grubości 1 mm, charakteryzującą się wysoką przezroczystością (Rys. 31b). Tak zdefiniowany model umożliwił odwzorowanie obszaru zgrzewania, wraz z wyraźnie zaznaczonymi krawędziami pomiędzy strefą połączenia z różnych materiałów, a pozostałą powierzchnią folii.

a) b)



Rys. 31. Projektowanie CAD a) oprogramowanie Vision System Designer b) model 3D opakowania

Parametry materiału folii w silniku renderującym programu VSD zostały dobrane tak, aby możliwie wiernie odwzorować jej rzeczywiste właściwości optyczne. Materiał opakowania zamodelowano jako nieprzezroczysty, z minimalnym udziałem odbitego światła (Tab. 7).

Tabela 7. Parametry zastosowanych materiałów w silniku renderującym VSD

Obiekt	Odbicie kierunkowe	Odbicie rozproszone	Przezroczystość
Folia	0,9	0,1	0,95
Opakowanie	0,4	0,005	0

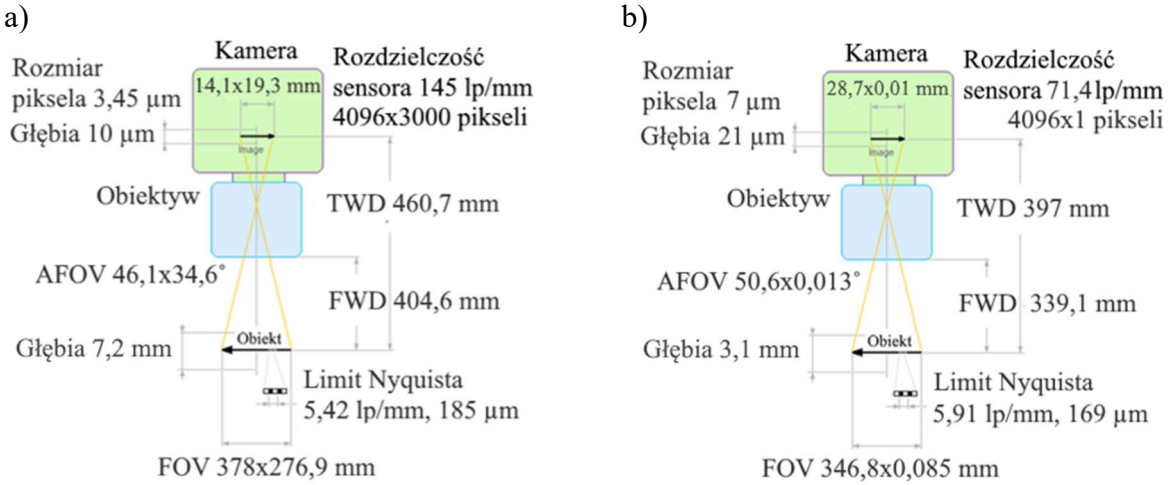
Wykorzystana w badaniach wersja oprogramowania VSD umożliwia natywne przetwarzanie wyłącznie danych z sensorów matrycowych, co oznacza, że nie wspiera bezpośredniej akwizycji obrazów z kamer liniowych. Z tego względu, w celu uzyskania danych odpowiadających rejestracji realizowanej za pomocą kamery liniowej, opracowano dedykowany algorytm rekonstrukcji obrazu. Polega on na sekwencyjnym łączeniu pojedynczych wierszy danych pozyskiwanych w stałych odstępach czasu, co pozwala odtworzyć sposób działania klasycznego sensora liniowego.

W ramach zrealizowanych badań symulacyjnych, porównane zostały układy obrazowania z kamerą liniową i matrycową. Do modelowania parametrów toru optycznego zastosowano generyczny model kamery, umożliwiający modyfikację kluczowych parametrów obrazowania. Istotnym ograniczeniem była jednak maksymalna możliwa rozdzielczość wirtualnego sensora, która wynosi 4096 pikseli w każdej z osi. Z tego względu, a także na podstawie wyznaczonego pola obrazowania $FOV_{L,}$ maksymalna rozdzielczość przestrzenna dla kamery liniowej wyniosła R_{Lmax}=0,084 mm/px, natomiast dla kamery matrycowej R_{Amax}= 0,092 mm/px. Uzyskanie takich parametrów wymaga zastosowania kamery z matrycowym sensorem 12 Mpx (4096 x 3000 px) oraz kamery liniowej 4K, z ustalonym stałym krokiem skanowania poniżej 0,1 mm. Do obydwu kamer dopasowane zostały modele obiektywów o standardowym kącie obserwacji. Podstawowe parametry obydwu opracowanych torów wizyjnych, przedstawione zostały w tabeli 8.

Tabela 8. Parametry wirtualnych torów wizyjnych

Parametr	Kamera matrycowa	Kamera liniowa
Wymiary sensora	14.13 x 10.35 mm	28.7 x 0.01 mm
Rozmiar piksela	3.45 µm	7 µm
Rozdzielczość sensora	4096 x 3000 px	4096 x 1 px
Ogniskowa obiektywu	14 mm	28 mm
Przysłona obiektywu	F/1.4	F/1.4

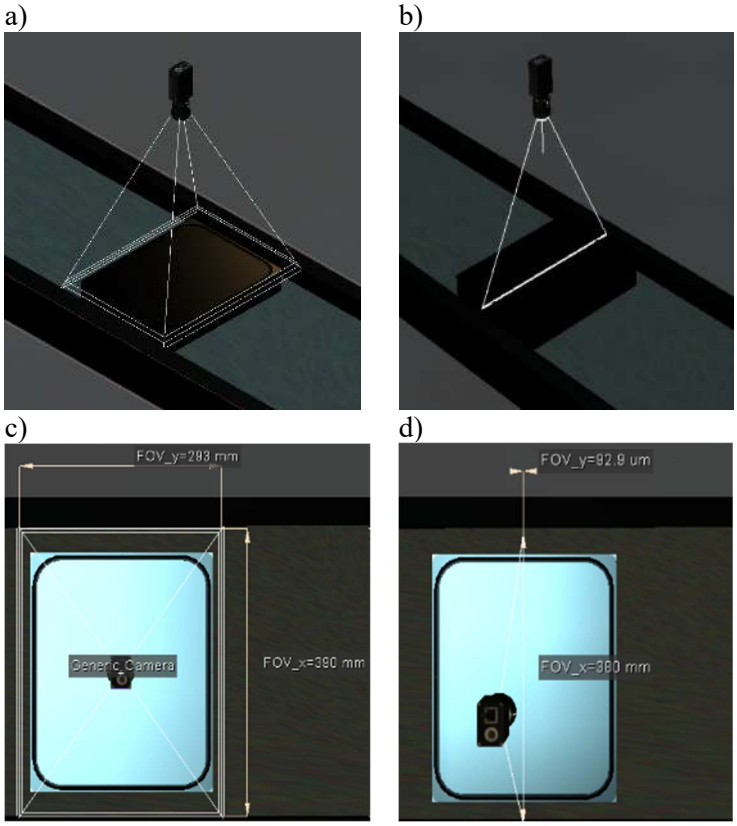
Na rysunku 32a przedstawiony został schemat toru wizyjnego z kamerą matrycową. Kątowe pole widzenia wyniosło AFOV=46,1x34°. Dla uzyskania wymaganego pola obserwacji, odległość pomiędzy czołem obiektywu i obiektem inspekcji została określona na FWD=404,6 mm. Przy ustalonych parametrach obiektywu głębia ostrości wyniosła DOF=7,173 mm. Przy zastosowaniu kamery liniowej, kątowe pole widzenia wyniosło θ_h=50,6°, natomiast głębia ostrości 3,104 mm przy zachowaniu odległości roboczej FWD=339,1 mm (Rys. 32b).



Rys. 32. Modelowe tory wizyjne a) kamera matrycowa b) kamera liniowa

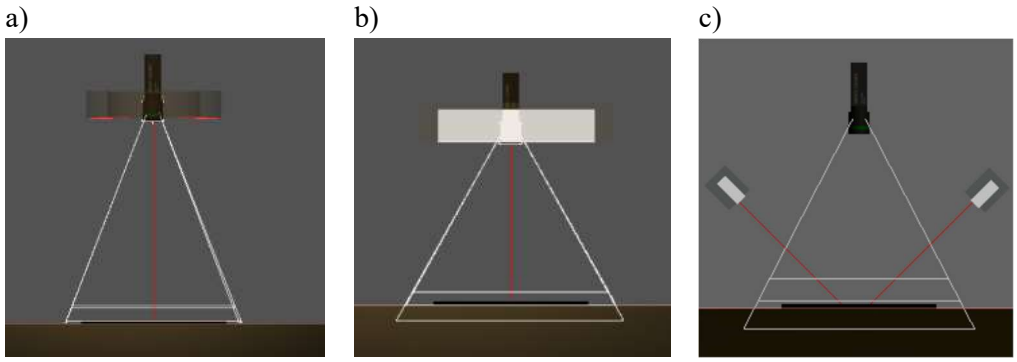
Zgodnie z kryterium Nyquista, oba opracowane tory optyczne charakteryzują się zdolnością detekcji obiektów o wymiarach przekraczających 0,2 mm. Oznacza to, że odpowiadające im dwie pary linii odwzorowanych w płaszczyźnie inspekcji posiadają co najmniej taki rozmiar, zapewniając spełnienie warunku próbkowania przestrzennego. W zastosowaniach przemysłowych systemów wizyjnych przyjmuje się, że obiekt musi zostać odwzorowany na siatce o wymiarach wynoszących co najmniej 2×2 piksele [160], aby zapewnić stabilną i powtarzalną detekcję w warunkach produkcyjnych. Analiza rozdzielczości obrazowania obu torów wizyjnych potwierdza spełnienie tego wymagania, co oznacza, że zaprojektowany układ optyczno-wizyjny gwarantuje detekcję obiektów o powierzchni przekraczającej 1 mm² w płaszczyźnie inspekcji oraz zachowuje odpowiedni margines bezpieczeństwa. Na rysunkach poniżej przedstawione zostały tory wizyjne wraz z docelowym obiektem inspekcji umieszczonym na uproszczonym modelu 3D transportera

(Rys. 33 a, b). Jak można zaobserwować uzyskane pola obserwacji zapewniają wymagany margines pozycjonowania (Rys. 33 c,d).



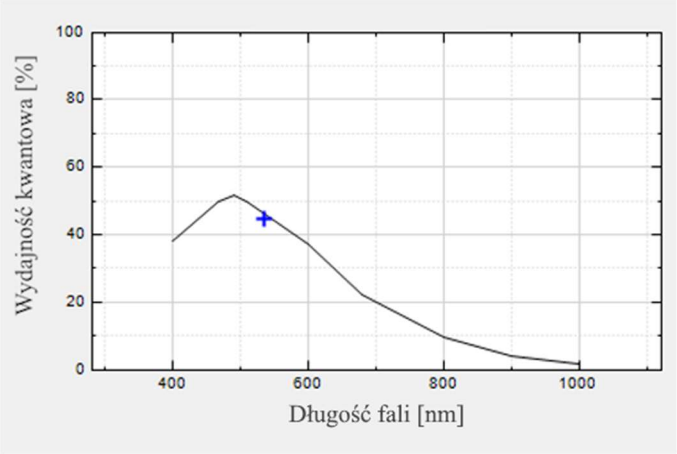
Rys. 33. Porównanie torów optycznych a) kamera matrycowa b) kamera liniowa c) FOV kamery matrycowej d) FOV kamery liniowej

W celu wykonania symulacji z katalogu dostępnych oświetlaczy wytypowano dwa oświetlacze dla układu z kamerą matrycową: pierścieniowy (Rys. 34a) oraz panelowy (Rys. 34b), który został umieszczony w taki sposób, aby odwzorowywać działanie oświetlenia typu kopuła płaska (*ang. flat dome*) z otworem znajdującym się w przecięciu osi symetrii. W przypadku kamery liniowej zastosowano klasyczny układ dwóch oświetlaczy liniowych (Rys. 34c).



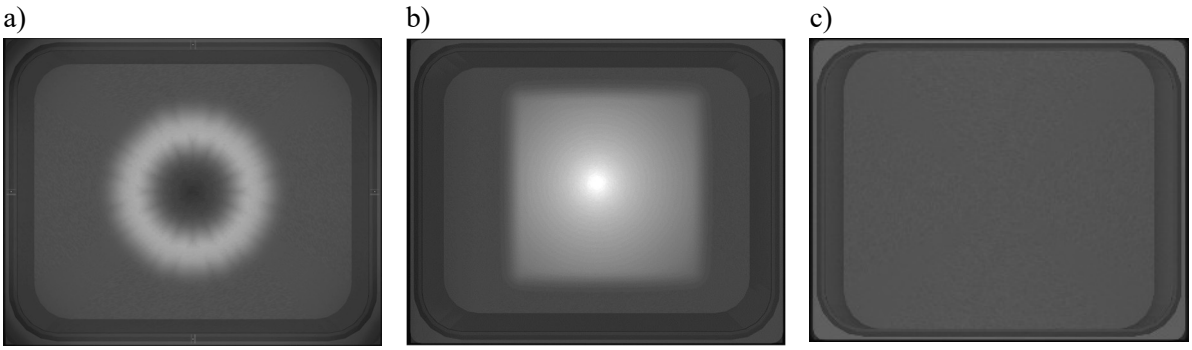
Rys. 34. Wytypowane oświetlacze a) pierścieniowy b) płaska kopuła c) liniowe

W przeprowadzonych symulacjach zastosowano kamerę generyczną o standardowej charakterystyce spektralnej (Rys. 35), odpowiadającej typowej czułości detektora w zakresie widzialnym. Tak dobrany model sensora umożliwił analizę wpływu barwy, współczynnika odbicia oraz właściwości optycznych materiałów na jakość wygenerowanych obrazów syntetycznych.



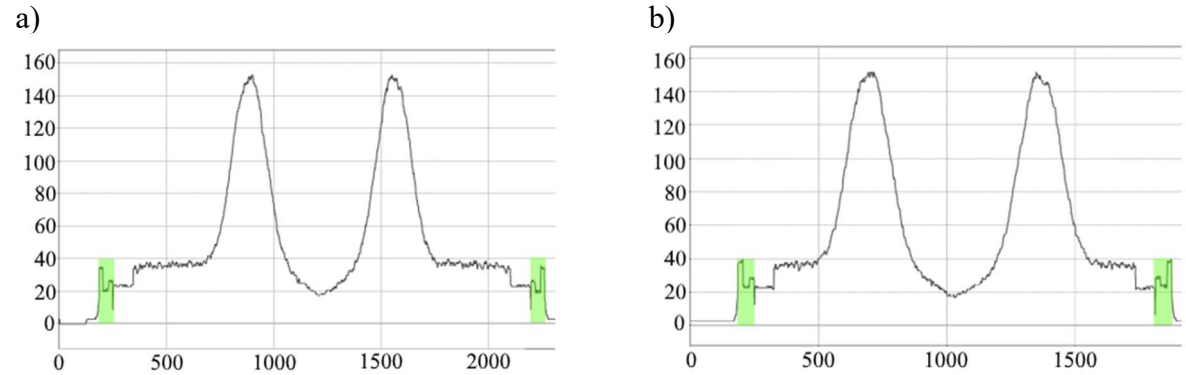
Rys. 35. Charakterystyka spektralna modelu kamery

Na rysunkach poniżej przedstawione zostały przykładowe obrazy zarejestrowane za pomocą opracowanych wirtualnych torów wizyjnych (Rys. 36 a, b, c).



Rys. 36. Zarejestrowane obrazy a) kamera matrycowa z oświetlaczem pierścieniowym b) kamera matrycowa z oświetlaczem typu płaska kopuła c) kamera liniowa z oświetlaczami liniowymi

Jak można zaobserwować, uzyskane obrazy wykazują istotne różnice w zakresie równomierności oświetlenia. W przypadku obrazu wygenerowanego przy zastosowaniu oświetlacza pierścieniowego w centralnej części pola widzenia widoczne jest charakterystyczne odbicie układu diod LED. Dodatkowo, ze względu na prostokątną geometrię obiektu inspekcji, obserwuje się wyraźne zróżnicowanie intensywności pikseli w kierunku wertykalnym (Rys. 37a) i horyzontalnym (Rys. 37b). Ma to szczególne znaczenie w obszarze inspekcji zgrzewu, który został zaznaczony kolorem zielonym na zarejestrowanych profilach jasności w osiach symetrii obrazu. Ponadto zastosowanie tego rodzaju oświetlenia znacząco ogranicza możliwość kontrolowania obszaru, w którym umieszczane są pakowane wyroby, a także weryfikacji etykiet, których poprawność również stanowi istotny element procesu.



Rys. 37. Porównanie profili jasności a) w osi horyzontalnej b) w osi wertykalnej obrazu

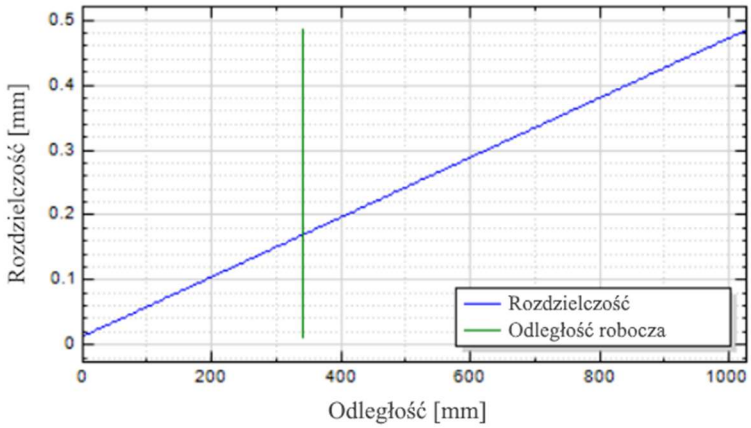
Wyznaczona różnica wartości profilu w lokalizacji odpowiadającej zewnętrznej krawędzi obszaru zgrzewania wyniosła 12,5% spadku intensywności dla osi horyzontalnej w porównaniu z osią wertykalną. Różnica tej wielkości może powodować trudności w opracowaniu skutecznych algorytmów detekcji i identyfikacji wad. Dla opakowań o większej dysproporcji pomiędzy wymiarami w osiach prostopadłych to niekorzystne zjawisko będzie miało jeszcze większe znaczenie. W układzie obrazowania wykorzystującym oświetlacz typu płaska kopuła możliwe jest uzyskanie równomiernego oświetlenia obszaru zgrzewania przy zapewnieniu jego odpowiednich wymiarów w obydwu osiach. Wadą tego rozwiązania jest jednak konieczność stosowania oświetlaczy o aktywnej powierzchni świecenia, zwykle nie mniejszej niż kontrolowany obszar wyrobu. Prowadzi to do wzrostu kosztów wdrożenia, wynikającego zarówno z liczby wymaganych diod LED, jak i konieczności zapewnienia odpowiedniej szczelności układu, wymaganej w przemyśle spożywczym. Stanowi to istotne ograniczenie pod względem skalowalności systemu oraz opłacalności jego wdrożenia. Układ obrazowania, składający się z kamery oraz dwóch oświetlaczy liniowych, umożliwia uzyskanie obrazów o wysokiej jakości pod względem równomierności oświetlenia. W przypadku konieczności zwiększenia wymiarów obszaru inspekcji wymagane jest jedynie wydłużenie oświetlaczy w jednej osi. Natomiast zwiększenie pola obserwacji w kierunku ruchu obiektu może zostać zrealizowane poprzez zwiększenie liczby linii składowych obrazu, co wymaga jedynie zapewnienia odpowiedniego bufora pamięci w układzie akwizycji danych.

Na podstawie przeprowadzonej analizy w dalszych pracach zastosowano układ wykorzystujący kamerę liniową. Zgodnie z przeprowadzoną symulacją układ ten umożliwia detekcję obiektu o minimalnych wymiarach 170 µm, zgodnie z teorią Nyquista. Rozdzielczość związana jest również z kontrastem, który może być analizowany za pomocą funkcji MTF (*ang. Modulation Transfer Function*) [161]. Wartość MTF całego toru wizyjnego jest wynikową wartością dla utraty kontrastu przez sensor kamery i zastosowany obiektyw. W tabeli 9, przedstawione zostały obliczone rozdzielczości przy typowych wartościach MTF. Za obraz o odpowiedniej ostrości przyjmuje się wartość MTF = 50%. Wartość MTF 10% uznaje się za graniczą przy której możliwa jest detekcja obiektów.

Tabela 9. Zależność rozdzielczości od wartości kontrastu MTF

Kontrast MTF [%]	Rozdzielczość w płaszczyźnie obrazu [lp/mm]	Rozdzielczość w odległości roboczej [mm]
80%	45,7	0,265
50%	81,4	0,149
20%	116	0,105
10%	129	0,094

Na rysunku 38 przedstawiona została zależność rozdzielczości przestrzennej w zależności od odległości roboczej opracowanego toru wizyjnego.



Rys. 38. Zależność rozdzielczości przestrzennej od odległości roboczej

Przedstawiona zależność pozwala określić wpływ zmiany wysokości obiektu inspekcji lub błędów podczas montażu układu obrazowania na rozdzielczość obrazowania. W tabeli 10 przedstawiony został wpływ zmiany położenia obiektu względem sensora na uzyskiwaną rozdzielczość oraz powiększenie, wynikający z przesunięcia obiektu o wartość ±5 mm względem referencyjnej odległości roboczej (WD).

Tabela 10. Zależność rozdzielczości od wartości kontrastu MTF

Zmiana odległości kamery od obiektu [mm]	Rozdzielczość w płaszczyźnie obrazu [mm]	Rozdzielczość w odległości roboczej [%]
- 5	0,168	1,35
0	0,177	0
+5	0,172	-1,35

Jak można zauważyć, opracowany tor wizyjny cechuje się dużą tolerancją na zmiany odległości roboczej, zachowując stabilną rozdzielczość obrazowania pomimo znaczących odchyłek położenia obiektu. Ograniczeniem w tym przypadku pozostaje jednak stosunkowo mała wartość głębi ostrości.

Mierniki jakości obrazów

W celu zaprojektowania odpowiedniej konfiguracji układu oświetlenia przyjęte zostały mierniki jakości obrazu, które w sposób obiektywny pozwoliły określić wpływ zmiennych na skuteczność detekcji wad w obszarze zgrzewania. Ocena jakości obrazu znajduje zastosowanie w wielu dziedzinach nauki i techniki. Istniejące metodyki obejmują zarówno podejścia subiektywne, jak i obiektywne [162]. Większość spośród opracowanych miar koncentruje się na percepcyjnych czynnikach jakości wizualnej, a ich celem jest prognozowanie jakości obrazu na podstawie właściwości ludzkiego układu wzrokowego. Subiektywne metody oceny polegają na analizie obrazów wyświetlanych na ekranach przez grupę ekspertów lub obserwatorów, którzy wyrażają swoje opinie z wykorzystaniem zdefiniowanej skali ocen. Z kolei metody obiektywne wykorzystują modele matematyczne do automatycznego i ilościowego szacowania jakości. Metryki te odgrywają również kluczową rolę w ewaluacji algorytmów przetwarzania obrazów. Omawiane rozwiązania obiektywne klasyfikuje się najczęściej do trzech podstawowych kategorii:

- pełnego odniesienia (*ang. Full Reference*),
- zredukowanego odniesienia (*ang. Reduced Reference*),
- bez odniesienia (*ang. No Reference*).

Podczas projektowania układów obrazowania za główne kryterium przyjmuje się maksymalizację kontrastu pomiędzy wadą, a jej bezpośrednim otoczeniem [154]. W takich przypadkach często stosuje się kontrast Michelsona (15), który odzwierciedla sposób postrzegania obrazów przez ludzki narząd wzroku.

$$K_{M=\frac{L_{Max}-L_{Min}}{L_{Max}+L_{Min}}} \tag{15}$$

gdzie:

L_{Max}, L_{Min} - maksymalna i minimalna wartość luminancji na obiekcie.

W analizie obrazów cyfrowych bardziej adekwatną miarą okazuje się jednak absolutna różnica intensywności w obszarze zainteresowania (16) [68].

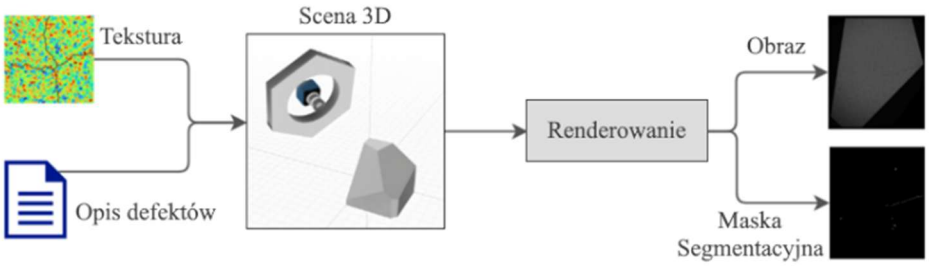
$$K_{Dig=G_{Max}-G_{Min}} \tag{16}$$

gdzie:

G_{Max}, G_{Min} - maksymalna i minimalna wartość pikseli w analizowanym obszarze.

W zadaniach związanych z detekcją wad większą odporność na lokalne zakłócenia daje zmodyfikowana definicja kontrastu K_{ROI}, w której oblicza się różnicę median pikseli między obszarem wady, a jego najbliższym otoczeniem. Pozwala to ocenić obrazy pod kątem ich potencjalnej skuteczności w algorytmach analizy obrazów. Dotyczy to szczególnie tych metod, które wykorzystują stałe wartości progów binaryzacji.

Wykorzystanie współczesnych silników renderujących w badaniach symulacyjnych umożliwia generowanie modeli syntetycznych wad o jednoznacznie określonej lokalizacji na powierzchni obiektu inspekcji (Rys. 39).



Rys. 39. Proces generowania obrazów syntetycznych wyrobów z wadami [163]

Takie podejście umożliwia zastosowanie mierników jakości wykorzystujących obraz referencyjny takich jak wskaźnik podobieństwa strukturalnego SSIM (*ang. Structural Similarity Index Measure*). Jest to miara porównawcza, która uwzględnia trzy składowe czynniki: jasności, kontrast oraz strukturę. Wartość indeksu SSIM pomiędzy dwoma obszarami X i Y określana jest wzorem [164]:

$$SSIM(x,y) = \frac{\left(2\mu_x\mu_y + c_1\right)\cdot\left(2\sigma_{xy} + c_2\right)}{\left(\mu_x^2 + \mu_y^2 + c_1\right)\cdot\left(\sigma_x^2 + \sigma_y^2 + c_2\right)} \tag{17}$$

gdzie:

μ_x – średnia jasność pikseli w oknie X,

μ_y – średnia jasność pikseli w oknie Y,

x_σ^2 – wariancja w oknie X,

y_σ^2 – wariancja w oknie Y,

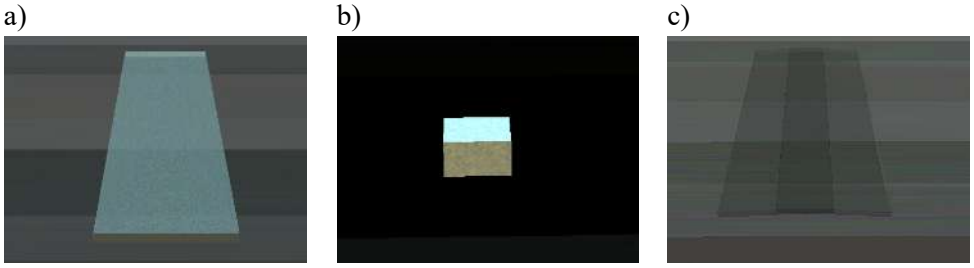
σ_{xy}– kowariancja pikseli w oknie X i Y,

c_1, c_2 – współczynniki stałe.

W przypadku symulacji cyfrowych, do oceny jakości obrazów syntetycznych może być wykorzystany wygenerowany obraz z oznaczonym regionem w postaci maski binarnej (*ang. ground truth mask*) [165]. Innym podejściem jest zastosowanie metod opartych na modelowaniu oczekiwanej odpowiedzi sygnałowej obrazu. W praktyce inżynierskiej przyjmuje się, że minimalny akceptowalny poziom sygnału do szumu wynosi SNR > 20 dB, natomiast za wartość zalecaną uznaje się SNR > 30 dB [166]. Jednocześnie intensywność rejestrowanych pikseli nie powinna przekraczać wartości 90% nasycenia detektora, gdyż może prowadzić to do utraty informacji [68]. Na tej podstawie, można przyjąć, że wartość pikseli w obszarze występowania wady na obrazie referencyjnym powinna wynosić pomiędzy 200-220 dla obrazu 8-bitowego.

Wyznaczenie kąta nachylenia oświetlaczy

W ramach zrealizowanych badań wykonano symulacje mające na celu określenie wpływu kąta nachylenia oświetlaczy względem osi kamery, na jakość rejestrowanych obrazów syntetycznych. W celu zasymulowania defektów występujących w obszarze zgrzewu opracowano ich syntetyczne modele 3D. Na podstawie informacji uzyskanych podczas wizyty w zakładzie produkcyjnym wykorzystującym zgrzewanie termiczne opakowań, opracowano modele wad w postaci zagniecenia (Rys. 40a), obszaru słabego zgrzewu (Rys. 40b) oraz zanieczyszczenia ciałem obcym (Rys. 40c). Defekt w postaci zagniecenia zamodelowano jako dwa nałożone na siebie prostopadłościany o wysokości 0,1 mm, obrócone o 5° względem górnej płaszczyzny opakowania. Wysokość modelu zanieczyszczenia względem powierzchni opakowania wynosiła 0,25 mm.



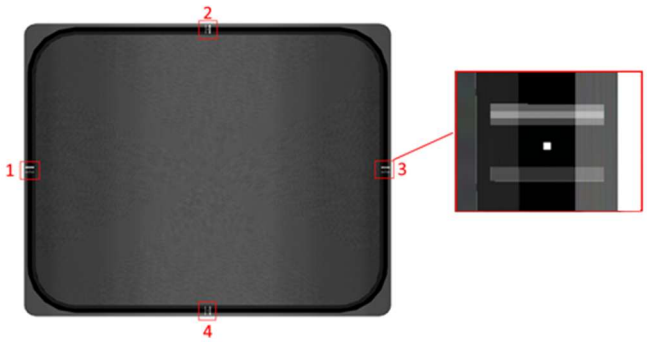
Rys. 40. Modele 3D pseudo-wad a) słaby zgrzew b) zanieczyszczenie c) zagniecenie

W tabeli 11 przedstawione zostały wymiary oraz parametry materiałów opracowanych modeli, które zostały zaimplementowane w silniku renderującym oprogramowania VSD.

Tabela 11. Parametry modeli syntetycznych wad

Typ wady	Odbicie kierunkowe	Odbicie rozproszone	Przezroczystość	Wymiary obrysu [mm x mm]
Zagniecenie	0,1	0,05	0,85	1,5x8
Słaby zgrzew	0,25	0,25	0,5	1x8
Zanieczyszczenie	0,08	0,44	0	5x5

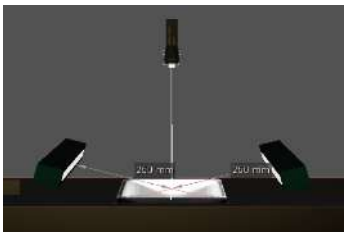
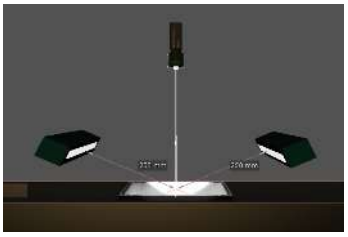
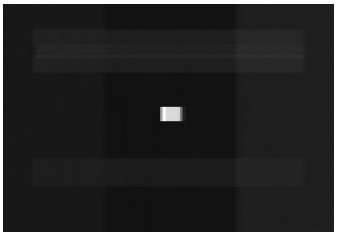
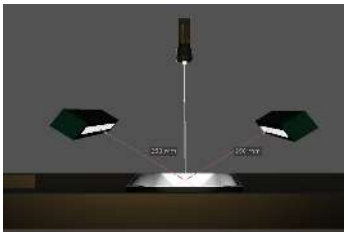
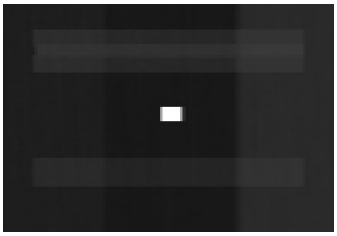
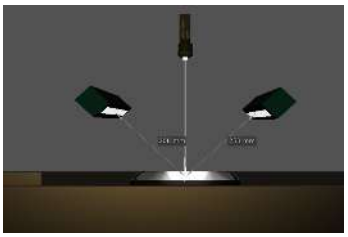
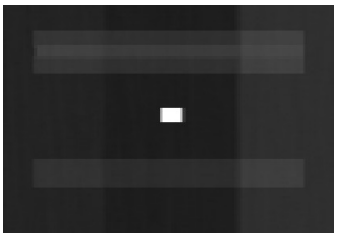
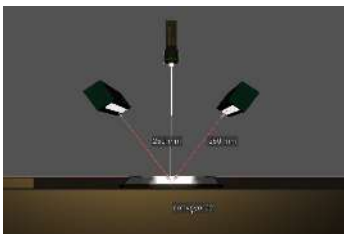
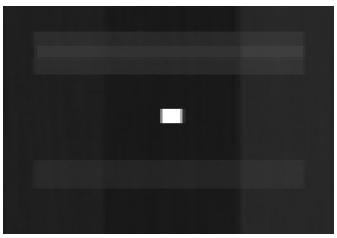
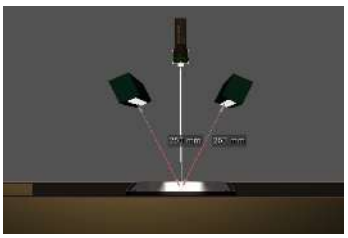
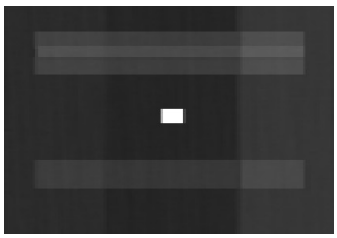
Opracowane obiekty symulujące wady zostały umieszczone w czterech lokalizacjach na powierzchni zgrzewu, w obszarze przecięcia z osiami głównymi opakowania (Rys. 41).



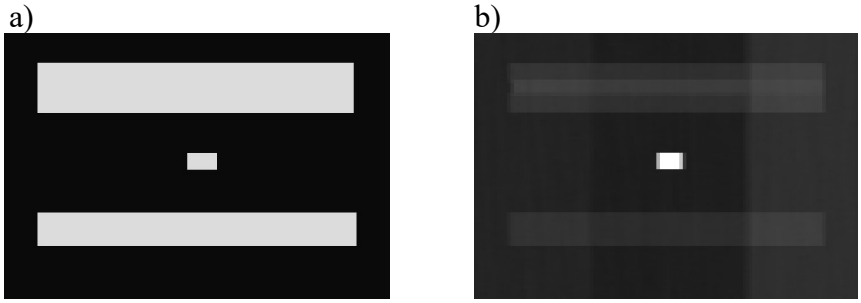
Rys. 41. Lokalizacje wygenerowanych wad w obszarze zgrzewania

W tabeli 12 przedstawione zostały testowane konfiguracje kątowe oświetlaczy w zakresie od 15˚ do 65˚ oraz przykładowe obrazy obszarów z wadami.

Tabela 12. Parametry modeli syntetycznych wad

Konfiguracja kąt nachylenia	Widok ogólny	Zarejestrowany obraz wad w lokalizacji nr 3
1 kąt - 15˚		
2 kąt - 25˚		
3 kąt - 35˚		
4 kąt - 45˚		
5 kąt - 55˚		
6 Kąt - 65˚		

Zarejestrowane obrazy poddano ocenie jakościowej. W tym celu, dla obszarów odpowiadających czterem lokalizacjom syntetycznych wad, obliczono wartości kontrastu K_{ROI} oraz wskaźnika SSIM (*ang. Structural Similarity Index*). W przypadku SSIM wykorzystano syntetyczny obraz referencyjny (Rys. 42a), w którym intensywność pikseli w obszarze wady ustawiono na wartość 220, natomiast intensywność tła na 10. Na rysunku 42b, przedstawiono przykładowy obraz wady.



Rys. 42. Porównanie obrazów syntetycznych a) referencyjnego b) zarejestrowanego

W tabeli 13 zaprezentowano wartości wybranych mierników jakości obrazów K_{ROI} i SSIM, wyznaczone jako średnie z czterech obszarów zawierających syntetyczne wady. Jak można zauważyć wartość SSIM przy obrazach ciemnych ma wysoką wartość, co jest znaną wadą tej metody [167]. Z tego względu opracowano metrykę oceny jakości obrazów, którą oznaczono jako wskaźnik jakości HQ. Została ona wyznaczona jako średnia harmoniczna wskaźnika SSIM i znormalizowanej wartości kontrastu K_{ROI_norm}.

Tabela 13. Ocena jakości obrazów

Konfiguracja kąt nachylenia	Kontrast K_{ROI}	Kontrast $K_{ROI\ norm}$	Wskaźnik SSIM	Wskaźnik jakości HQ
1 - kąt 15˚	5,62	0,02	0,53	0,04
2 - kąt 25˚	10,54	0,04	0,49	0,08
3 - kąt 35˚	14,59	0,06	0,45	0,10
4 - kąt 45˚	19,03	0,07	0,43	0,13
5 - kąt 55˚	15,33	0,06	0,45	0,11
6 - kąt 65˚	24,03	0,09	0,41	0,15

Analiza uzyskanych wyników pozwala sklasyfikować zakres kątów nachylenia od 45° do 65° jako optymalny dla detekcji zasymulowanych typów wad. Powyższe ustalenia stanowiły punkt wyjścia dla dalszych badań laboratoryjnych, w ramach, których poddano analizie jakość obrazów rzeczywistych obiektów inspekcji.

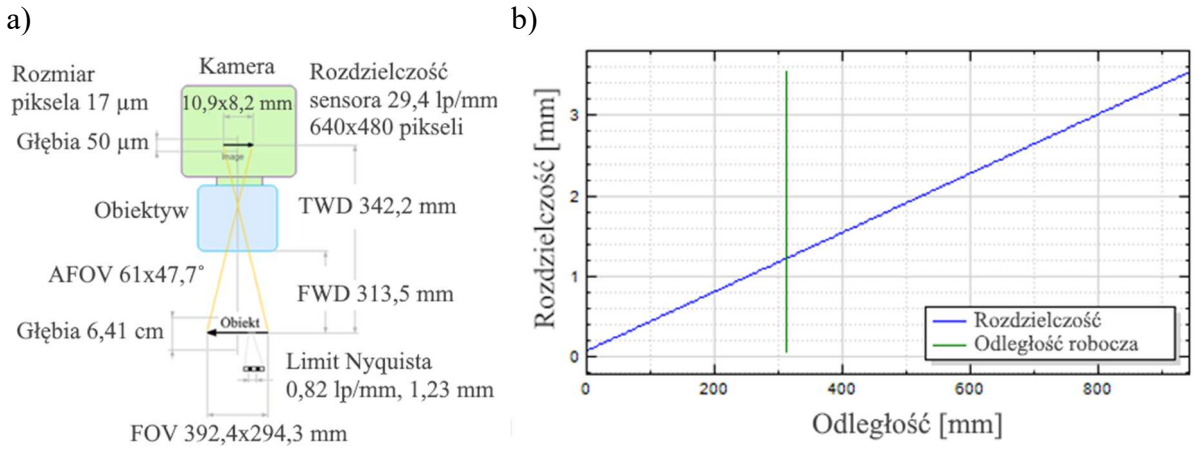
Kamera termowizyjna

Ze względu na zastosowanie w koncepcji układu hybrydowego kamery termowizyjnej w układzie pasywnym, modelowanie tego modułu ograniczono do wyznaczenia podstawowych parametrów toru wizyjnego z wykorzystaniem generycznego modelu kamery matrycowej. Pomimo sukcesywnego obniżania kosztów wytwarzania detektorów mikrobolometrycznych, przemysłowe systemy termowizyjne nadal wykazują ograniczenia w zakresie oferowanej rozdzielczości. Najczęściej wykorzystuje się sensory w formatach QVGA (320×240 px) oraz VGA (640×480 px). Parametry te są jednak wystarczające do wyznaczania profilu temperaturowego obszaru zgrzewania, którego szerokość wynosi typowo 10 mm [145]. Zestawienie podstawowych parametrów opracowanego toru wizyjnego kamery IR przedstawiono w tabeli 14.

Tabela 14. Parametry toru wizyjnego kamery IR

Wymiary sensora	10.9 x 8.12 mm
Rozmiar piksela	17 µm
Rozdzielczość sensora	640 x 480 px
Ogniskowa obiektywu	9 mm
Przysłona obiektywu	F/1.4

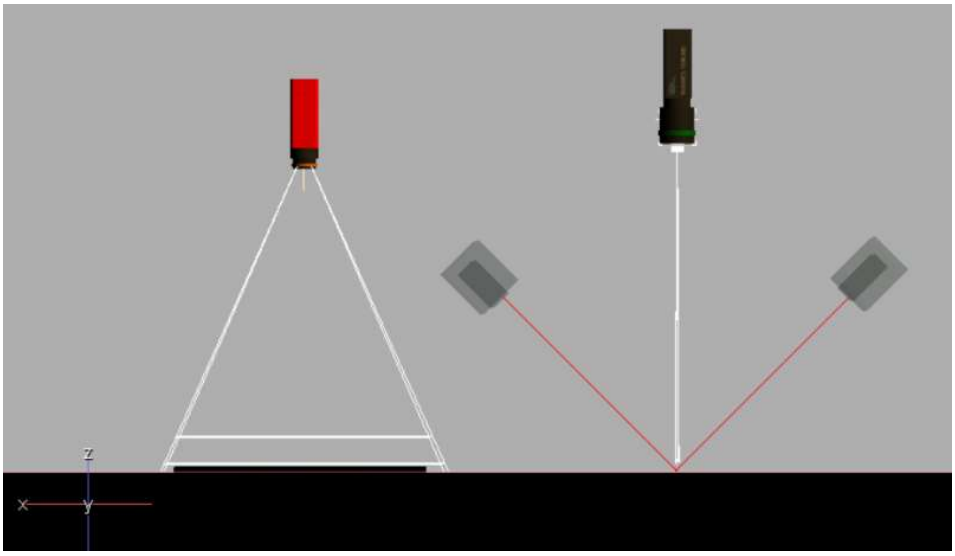
Na rysunku 43a przedstawiony został schemat toru wizyjnego kamery IR. Kątowe pole widzenia, wyniosło AFOV=61x47,7°. Dla uzyskania wymaganego pola obserwacji, odległość pomiędzy czołem obiektywu i obiektem inspekcji została określona na FWD=313,4 mm. Przy ustalonych parametrach obiektywu głębia ostrości wyniosła DOF=64,1 mm. Na rysunku 43b przedstawiona została zależność rozdzielczości przestrzennej w zależności od odległości roboczej opracowanego toru wizyjnego.



Rys. 43. Modelowy tor wizyjny kamery IR a) podstawowe parametry b) zależność rozdzielczości przestrzennej od odległości roboczej

Tak jak w przypadku kamery pasma widzialnego, zmiana wartości referencyjnej WD powoduje nieznaczną zmianę rozdzielczości. Głębia ostrości kamery wynosi natomiast 64 mm. Rozdzielczość przestrzenna obrazowania wyniosła w przedstawionej konfiguracji 0,61 mm/px, a minimalna wielkość wykrywanego obiektu 1,23 mm.

Opracowana koncepcja układu hybrydowej optycznej inspekcji opakowań została przedstawiona na rysunku 44. Inspekcja za pomocą modułów wizyjnych wykonywana jest sekwencyjnie.



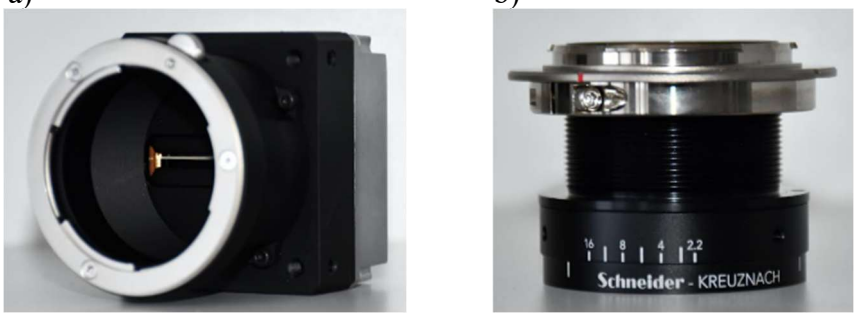
Rys. 44. Model hybrydowego systemu inspekcji opakowań zgrzewanych termicznie

W pierwszej kolejności ze względu na zjawisko stygnięcia wykonywana jest inspekcja za pomocą kamery termowizyjnej. Następnie wykonywane jest skanowanie za pomocą kamery pasma widzialnego. Zarejestrowane obrazy poddawane są następnie przetwarzaniu i fuzji danych w celu detekcji anomalii w obszarze zgrzewania.

4.3. Stanowisko badawcze

W celu weryfikacji opracowanej koncepcji systemu hybrydowej inspekcji wykorzystane zostało stanowisko laboratoryjne umożliwiające prowadzenie badań eksperymentalnych z zastosowaniem wytypowanych metod obrazowania. Zastosowany układ mechatroniczny stanowi fizyczną implementację opracowanego modelu, umożliwiającą wykonanie analizy architektury torów wizyjnych, parametrów optycznych oraz procesu akwizycji obrazów. Konstrukcja stanowiska umożliwia regulację geometrii układu inspekcji w szerokim zakresie. Do budowy stanowiska wykorzystano dostępne w Łukasiewicz-ITeE komponenty układów obrazowania, których parametry techniczne były zbliżone do modelowych torów wizyjnych. Do akwizycji obrazów w paśmie widzialnym zastosowano kamerę liniową raL6144 firmy Basler (Rys. 45a). Do sensora wytypowany został obiektyw Emerald 2.2/50F producenta Schneider Kreuznach (Rys. 45b).

a) b)



Rys. 45. Wytypowane elementy układu obrazowania VIS a) kamera liniowa b) obiektyw

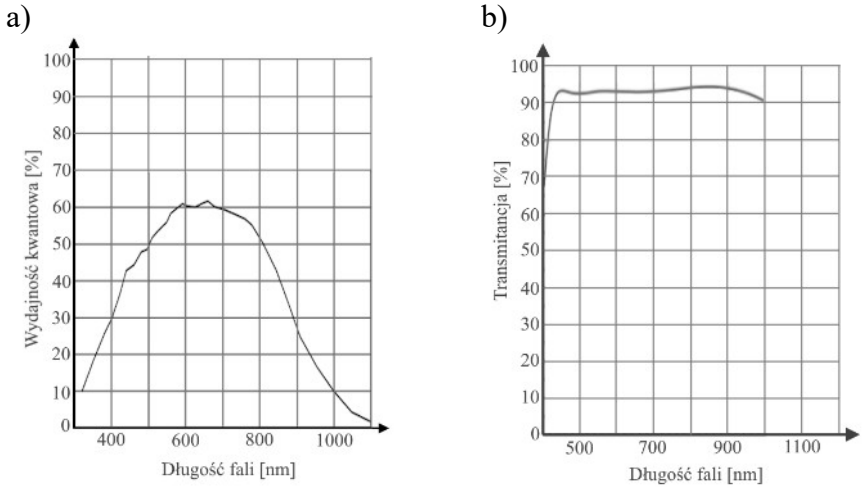
Podstawowe parametry zastosowanych elementów toru wizyjnego VIS przedstawione zostały w tabeli 15. W celu zwiększenia rozdzielczości obrazowania do badań eksperymentalnych użyty został sensor Awaiba DR-6k-7.

Tabela 15. Parametry toru wizyjnego VIS

Wymiary sensora	43,01 x 0,01 mm
Zakres spektralny	400 - 1000 nm
Rozmiar piksela	7 µm
Rozdzielczość sensora	6144 x 1 px
Częstotliwość akwizycji	17 kHz
Ogniskowa obiektywu	50 mm
Przysłona obiektywu	F/2.2 - F/16
Minimalny WD	155 mm

Na rysunku 46a przedstawiony został wykres spektralny efektywności kwantowej użytego sensora. Jak można zaobserwować najwyższa czułość matrycy występuję w zakresie od 500 do 800 nm. Transmisyjność zastosowanego obiektywu jest w przybliżeniu stała w zakresie od 450 nm do 900 nm (Rys. 46b).

a) b)



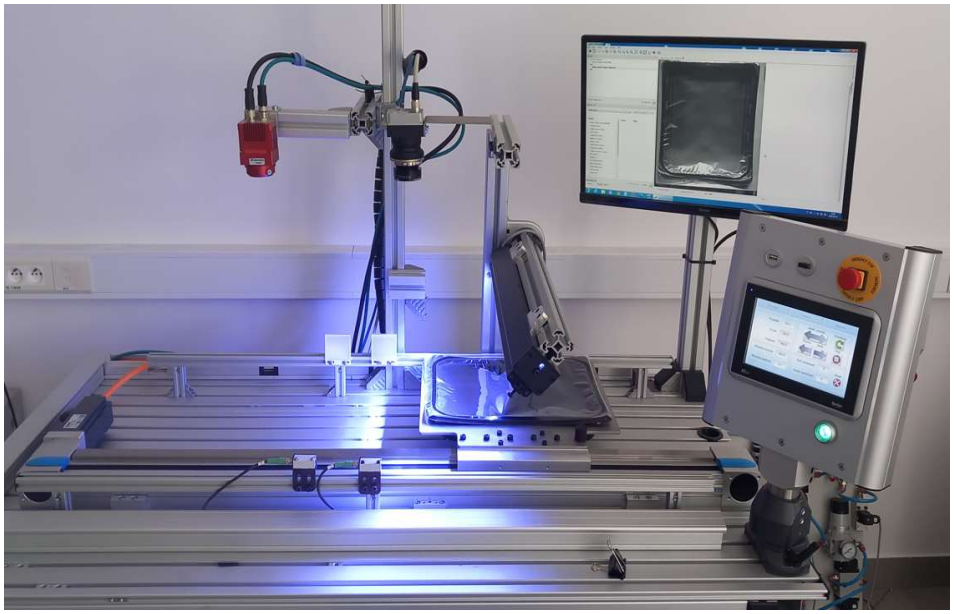
Rys. 46. Wykresy spektralne a) wydajność kwantowa [168] b) transmisyjność obiektywu [169]

W celu umożliwienia analizy profilu temperaturowego obszaru zgrzewania, wytypowana została kamera termowizyjna IRSX-I-640 firmy AT Sensors, dedykowana do zastosowań przemysłowych. Podstawowe parametry toru wizyjnego IR przedstawione zostały w tabeli 16.

Tabela 16. Parametry toru wizyjnego IR

Typ sensora	Mikrobolometryczny
Zakres spektralny	7,5 - 13 µm
Zakres pomiarowy	–25 to +140 °C
Czułość termiczna	< 30 mK
Dokładność pomiaru	±2 °C lub ±2 % odczytu
Rozmiar piksela	17 µm
Rozdzielczość sensora	640 x 512 px
Częstotliwość akwizycji	30 Hz
Ogniskowa obiektywu	9 mm
Przysłona obiektywu	F/1.25
Minimalny WD	32 mm

Platforma badawcza została wyposażona w napęd liniowy, który umożliwia transport obiektów do strefy inspekcji z zakładaną prędkością 400 mm/s, zapewniając realizację testów w warunkach zbliżonych do operacyjnych (Rys. 47).



Rys. 47. Stanowisko badawcze ze zintegrowanym napędem liniowym

Wykorzystanie dedykowanych adapterów montażowych oraz modułowej konstrukcji opartej na profilach aluminiowych umożliwiło konfigurowanie i testy różnych wariantów torów wizyjnych (Rys. 48a). W celu odwzorowania warunków zbliżonych do przemysłowego procesu pakowania, stanowisko badawcze zostało wyposażone w zgrzewarkę (Rys. 48b) manualną z matrycą zgodną ze standardem stosowanym w zakładach produkcyjnych.

a) b)



Rys. 48. Stanowisko badawcze z oświetlaczem współosiowym c) zgrzewarka opakowań

Sterowanie napędem liniowym odbywa się za pomocą sterownika PLC. Zadawanie parametrów ruchu odbywa się z wykorzystaniem panelu dotykowego. Konfiguracja systemów wizyjnych możliwa jest za pomocą oprogramowania komputerowego. Badany obiekt umieszczany jest w module transportowym, który umożliwia przemieszczanie obiektu względem układów wizyjnych. Odbiciowe czujniki optyczne zainstalowane na stanowisku wykrywają obecność poruszającego się obiektu i umożliwiają wyzwalanie akwizycji obrazów.

Zgodnie z opracowaną koncepcją do oświetlenia strefy inspekcji wykorzystano dwa oświetlacze liniowe (Rys. 49). Ze względu na konieczność detekcji obiektów o różnych barwach zastosowano diody LED o barwie białej, których szerokie widmo emisyjne zapewnia uniwersalność.



Rys. 49. Tor wizyjny VIS z dwoma oświetlaczami liniowymi

Istotnym zagadnieniem podczas inspekcji obiektów niestacjonarnych jest zjawisko rozmycia obrazu (B). Wielkość tego efektu można wyznaczyć na podstawie następującego równania:

$$B = \frac{v \cdot T_e \cdot N}{FOV} \tag{18}$$

gdzie:

v - prędkość obiektu,

T_e - czas ekspozycji,

N - liczba pikseli sensora w kierunku ruchu,

FOV - rozmiar pola obserwacji w kierunku ruchu.

W przypadku kamery liniowej rozmiar sensora w kierunku ruchu wynosi N=1 px, natomiast rozmiar obserwowanego pola FOV może być wyznaczony na podstawie rozdzielczości obrazowania określonej podczas modelowania toru wizyjnego (R_{Lmax}=0,084 mm/px). Przyjmując, zgodnie z praktyką inżynierską maksymalne rozmycie obrazu 0,5 piksela [170] oraz prędkość ruchu v=400 mm/s, wyznaczony czas ekspozycji kamery dla projektowanego układu nie powinien być większy niż T_e=0,1 ms. Analiza wykonanych rejestracji wykazała, że redukcja czasu migawki do wyznaczonej wartości spowodowała istotne obniżenie jasności rejestrowanych obrazów. W celu zwiększenia poziomu sygnału, wykorzystano funkcję kamery umożliwiającą sumowanie sygnału analogowego rejestrowanego przez dwa sąsiednie piksele (*ang. pixel binning*) [171]. Wadą tego rozwiązania jest jednak zmniejszona dwukrotnie rozdzielczość obrazowania, ale przy zachowaniu tego samego pola obserwacji i zwiększeniu częstotliwości skanowania.

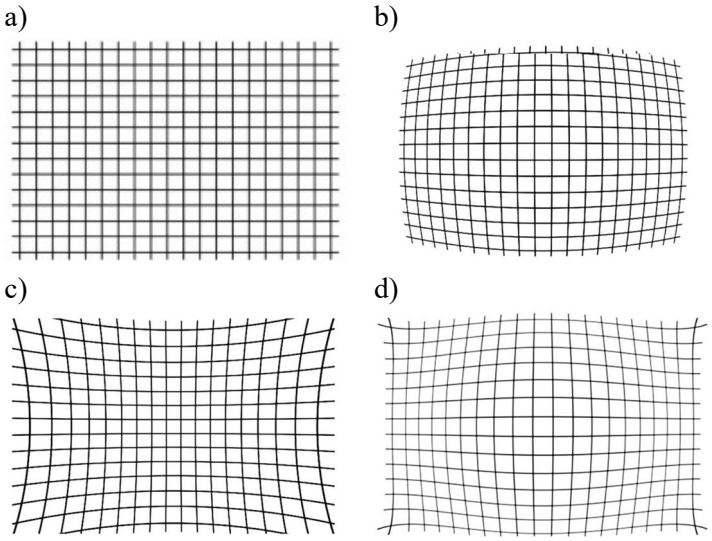
4.4. Metoda kalibracji i rejestracji obrazów

Zastosowanie metod fuzji obrazów w zależności od poziomu integracji danych może wymagać przeprowadzenia transformacji zarejestrowanych obrazów (*ang. image registration*) do wspólnego układu współrzędnych. Dokładność tej operacji jest determinowana zarówno skutecznością zastosowanego algorytmu dopasowania, jak również zniekształceniami optycznymi występującymi w obrazach pozyskiwanych za pomocą poszczególnych układów obrazowania.

Kalibracja torów wizyjnych

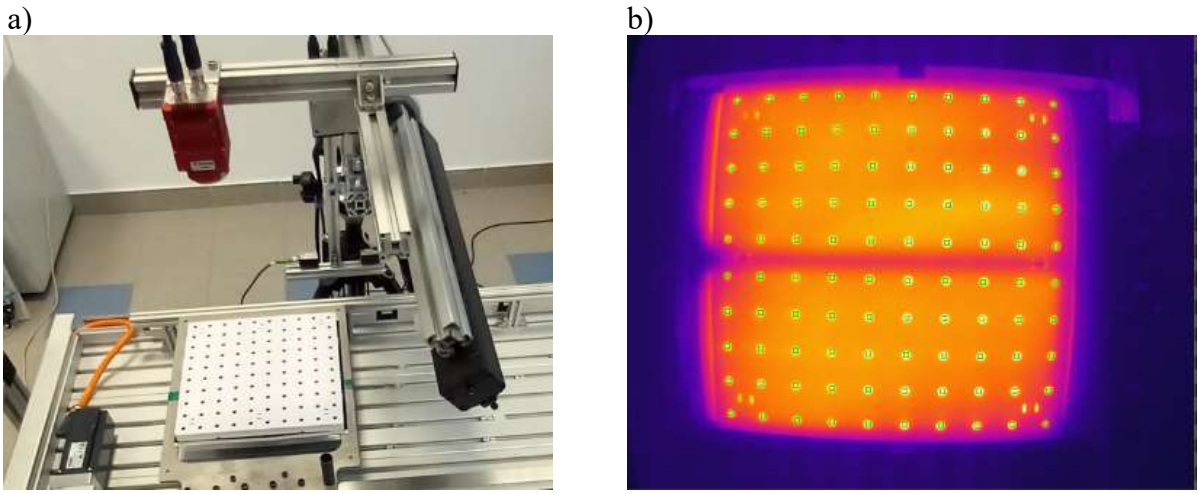
W zależności od wewnętrznej budowy układów zwierciadeł w obiektywach, układy wizyjne narażone są na występowanie zniekształceń optycznych. Objawiają się one jako zakrzywienia prostych linii na obrazie (Rys. 50a). Błędy te są minimalizowane za pomocą metod kalibracji kamer, w ramach których wyznacza się parametry wewnętrzne i zewnętrzne

układu Wyróżnić można kilka rodzajów dystorsji [172]: beczkową (*ang. barrel distortion*) (Rys. 50b), poduszkową (*ang. pincushion distortion*) (Rys. 50c) oraz falistą (*ang. mustache distortion*) (Rys. 50d).



Rys. 50. Rodzaje dystorsji a) brak b) beczkowa c) poduszkowa d) falista [172]

Ze względu na znaczące zniekształcenia optyczne układu obrazowania kamery termowizyjnej, konieczne było zastosowanie operacji korekcji obrazów [173]. Proponowane rozwiązanie wymaga zastosowania wzorca kalibracyjnego (Rys. 51a), którego charakterystyczne punkty cechują się wysokim kontrastem w paśmie LWIR. Opracowany wzorzec składa się z maty grzewczej i maskownicy z otworami przelotowymi o znanym rozstawie. Poniżej przedstawiono przykładowy termogram z widoczną dystorsją (Rys. 51b).



Rys. 51. Kalibracja obrazów z kamery termowizyjnej a) wzorzec kalibracyjny b) zarejestrowany termogram po operacji pseudo-kolorowania

Ogólny model korekcji dystorsji, można zapisać w następującej postaci, rozdzielając komponenty radialne oraz tangencjalne [174]:

$$x' = x + \bar{x} \cdot (d_r + d_t) \tag{19}$$

$$y' = y + \bar{y} \cdot (d_r + d_t)$$

gdzie:

dystorsja radialna - $d_r = k_1 r^2 + k_2 r^4 + k_3 r^6 + \cdots$

dystorsja tangencjalna - $d_t = [p_2(r^2 + 2y^{-2}) + 2p_1\overline{xy}] \cdot (1 + p_3 r^3 + \cdots)$

współrzędne względem punktu głównego - $\bar{x} = x - x_0$, - $\bar{y} = y - y_0$

odległość względem punktu głównego - $r = \sqrt{\bar{x}^2 + \bar{y}^2}$

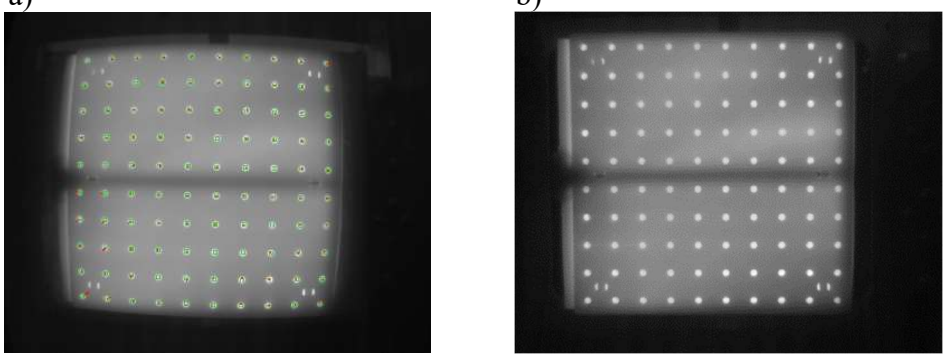
W tabeli 17 przedstawione zostały wyznaczone podczas kalibracji parametry modelu kamery perspektywicznej zaimplementowanego w oprogramowaniu Aurora Vision Studio [175].

Tabela 17. Wyznaczone parametry wewnętrzne modelu kamery IR

Parametr	Wartość
Średni błąd reprojekcji (RMS)	0,13 [px]
Współrzędna X punktu głównego	304,78 [px]
Współrzędna Y punktu głównego	280,51 [px]
Dystorsja obiektywu K1	-11,8e-1
Dystorsja obiektywu K2	11,0e-1
Dystorsja obiektywu P1	-16,3e-3
Dystorsja obiektywu P2	70,2e-4
Dystorsja obiektywu K3	11,3e-1
Dystorsja obiektywu K4, K5, K6	0

Podczas kalibracji wyznaczane są wektory błędów (Rys. 52a) i następnie na ich podstawie mapa rektyfikacji obrazu, która umożliwiła korekcję zniekształceń (Rys. 52b).

a) b)



Rys. 52. Kalibracja IR a) obraz wejściowy z wektorami błędów b) obraz po rektyfikacji

W zastosowanym dla kamery IR modelu uwzględniono wyłącznie te parametry wewnętrzne, które pozostają niezmienne przy zmianie pozycji i orientacji kamery. Dzięki temu nie ma konieczności ponownej kalibracji układu po rekonfiguracji układu obrazowania. W przypadku kamery pasma widzialnego zastosowano natomiast model kamery liniowej, obejmujący pełny zestaw parametrów układu obrazowania, wraz z uwzględnieniem wpływu ruchu na proces akwizycji. Z tego względu każdorazowa zmiana konfiguracji toru wizyjnego lub parametrów przesuwu obiektu inspekcji wymaga ponownego przeprowadzenia kalibracji. W tabeli 18 przedstawiono wewnętrzne parametry kamery VIS wyznaczone podczas badań laboratoryjnych.

Tabela 18. Wyznaczone parametry wewnętrzne modelu kamery VIS

Parametr	Wartość
Średni błąd reprojekcji (RMS)	0,96 [px]
Współrzędna X punktu głównego	1536 [px]
Dystorsja obiektywu K1, K2, K3	0
Dystorsja obiektywu P1, P2	0
Dystorsja obiektywu K4	0,037
Dystorsja obiektywu K5, K6	0

Zgodnie z zastosowaną procedurą kalibracji, wartość ogniskowej wyrażonej w pikselach nie jest wyznaczana automatycznie. Może być jednak obliczona na podstawie parametrów technicznych kamery zgodnie z następującą zależnością:

$$f_{px} = \frac{f_l}{p_p \cdot d} \tag{20}$$

gdzie:

f_l - ogniskowa obiektywu [mm],

p_p - odległość pomiędzy pikselami (*ang. pixel pitch*) [mm/px],

d - skalowanie obrazu.

Wartość ogniskowej dla rozpatrywanej konfiguracji toru wizyjnego wyniosła f_{px}=7142,86 px. Parametry zastosowanego modelu kamery liniowej obejmują ponadto:

- V_{YI} - parametr określający zależność częstotliwości skanowania i prędkości ruchu transportera względem kamery,
- S_Y - odchylenie sensora względem osi pionowej,
- P_R - odchylenie płaszczyzny pasa transmisyjnego wokół osi podłużnej,
- P_D - odległość sensora od referencyjnej płaszczyzny ruchu.

W tabeli 19 zestawiono wyznaczone podczas badań laboratoryjnych parametry zewnętrzne kamery VIS, które opisują jej orientację względem układu odniesienia stanowiska inspekcyjnego.

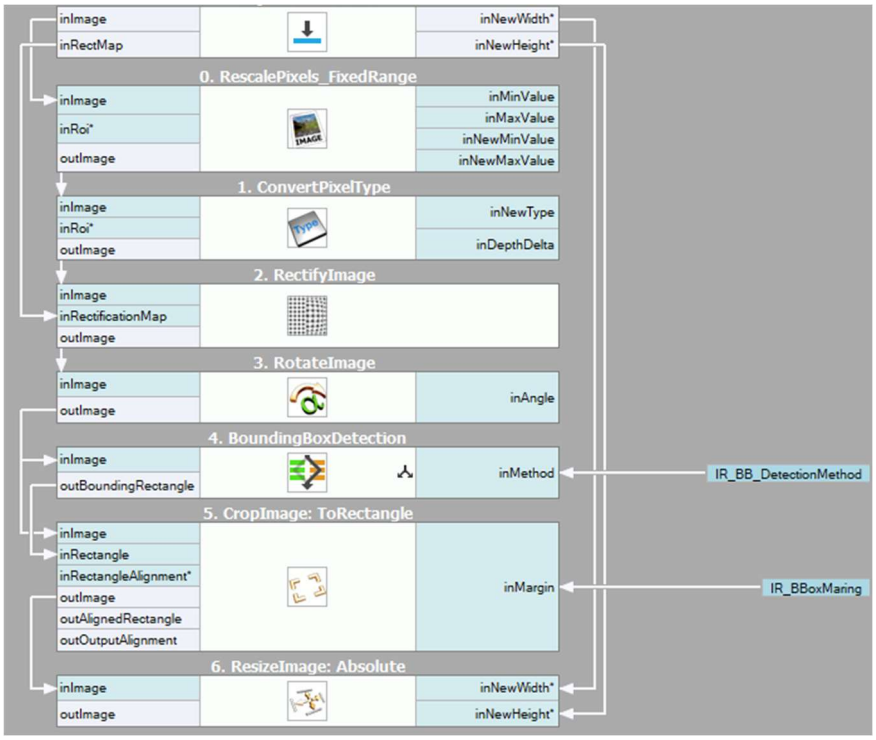
Tabela 19. Wyznaczone parametry zewnętrzne modelu kamery VIS

Parametr	Wartość
V_{YI}	7,98 [px/mm]
S_Y	0,01 [˚]
P_R	0,01 [˚]
P_D	458,5 [mm]

Uzyskane wyniki wskazują na prawidłowe ustawienie kątowe sensora kamery względem płaszczyzny obrazowania. Wyznaczona rozdzielczość 8 px/mm spełnia wymagania założone dla toru wizyjnego kamery pasma widzialnego. Ze względu na większy fizyczny rozmiar zastosowanego sensora, wzrosła również odległość robocza względem parametrów wirtualnego toru wizyjnego.

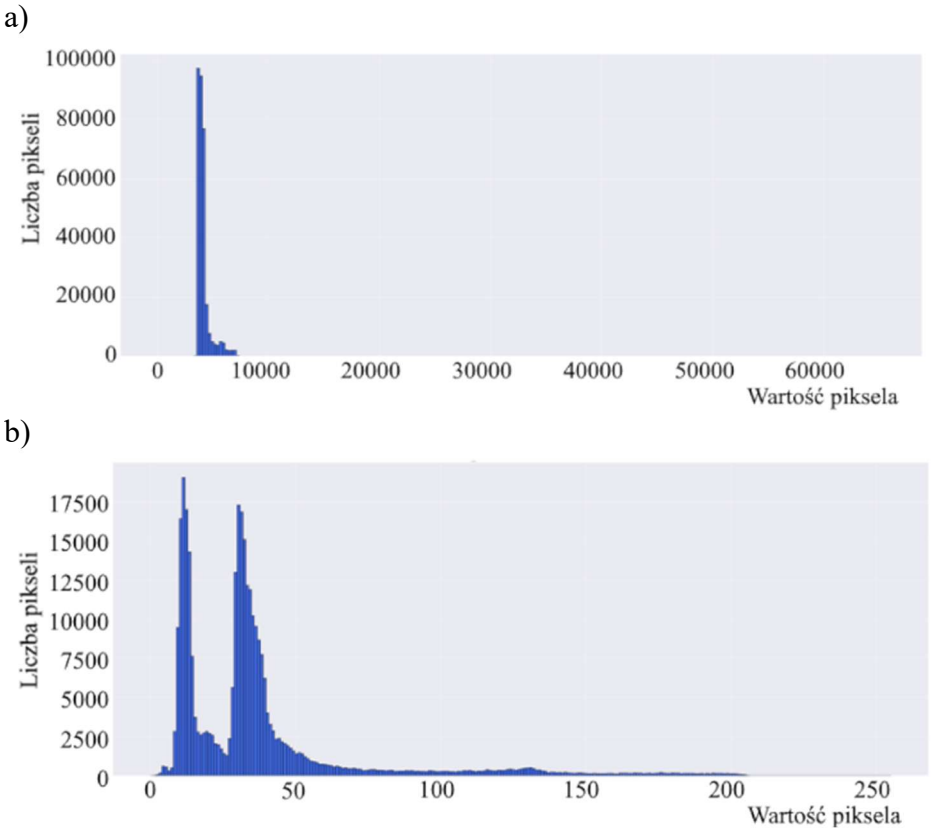
Rejestracja obrazów oraz transformacja do wspólnego układu odniesienia

Istotnym etapem opracowanego algorytmu inspekcji jest rejestracja obrazów IR i VIS do wspólnego układu współrzędnych za pomocą dedykowanego algorytmu [176]. W tym celu, w pierwszej kolejności wykonywane jest wstępne przetwarzanie obrazów termowizyjnych (Rys. 53). Zastosowany w kamerze przetwornik analogowo-cyfrowy umożliwia rejestrację obrazów o 12-bitowej głębi. Z tego względu analizowane dane zapisywane są w niestandardowym formacie 16-bitowych zmiennych (2 bajtów). Rozwiązanie to jest nieefektywne zarówno pod względem wykorzystania pamięci, jak i wydajności algorytmów.



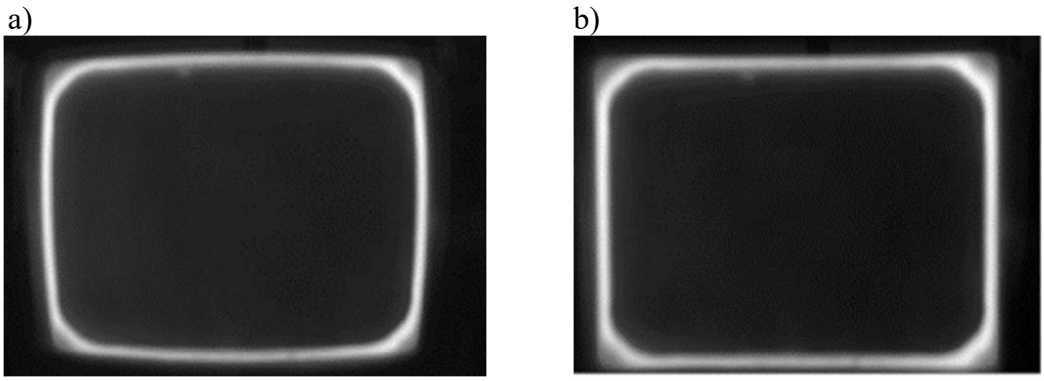
Rys. 53. Algorytm rejestracji obrazów IR

Na wykresach poniżej przedstawione zostały histogramy obrazu zarejestrowanego przez kamerę IR (Rys. 54a) oraz po przetworzeniu do formatu 8-bitowego (Rys. 54b).



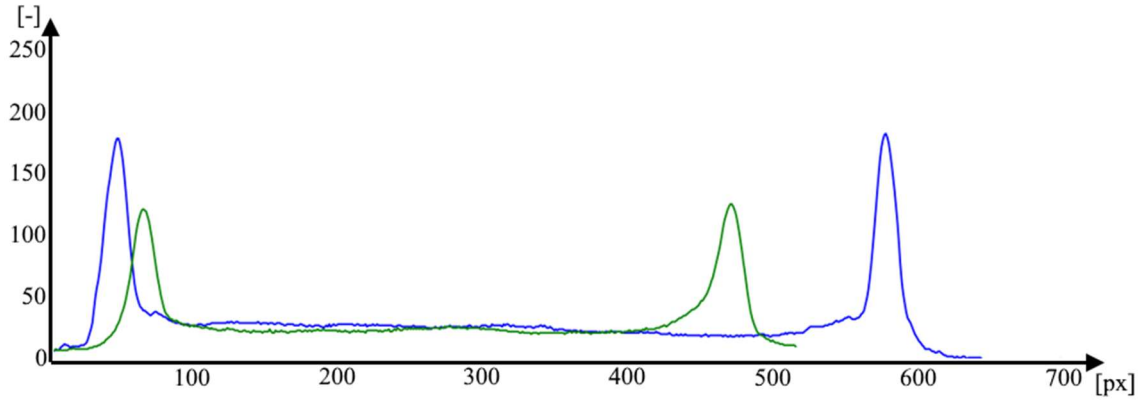
Rys. 54. Histogram obrazu a) zarejestrowanego przez kamerę b) po przetworzeniu

Zastosowana funkcja skalowania danych umożliwia ograniczenie analizowanego zakresu wartości, a następnie ich normalizację do postaci odpowiadającej standardowemu obrazowi 8-bitowemu. Dzięki tej operacji uzyskuje się poprawę kontrastu pomiędzy obszarem zgrzewu, a tłem, a także zwiększona zostaje wydajność algorytmów (Rys. 55a). W dalszej kolejności, na podstawie mapy odkształceń wyznaczonej podczas procesu kalibracji, wykonywana jest operacja rektyfikacji. Przetworzone obrazy (Rys. 55b) mogą być następnie poddane analizie.



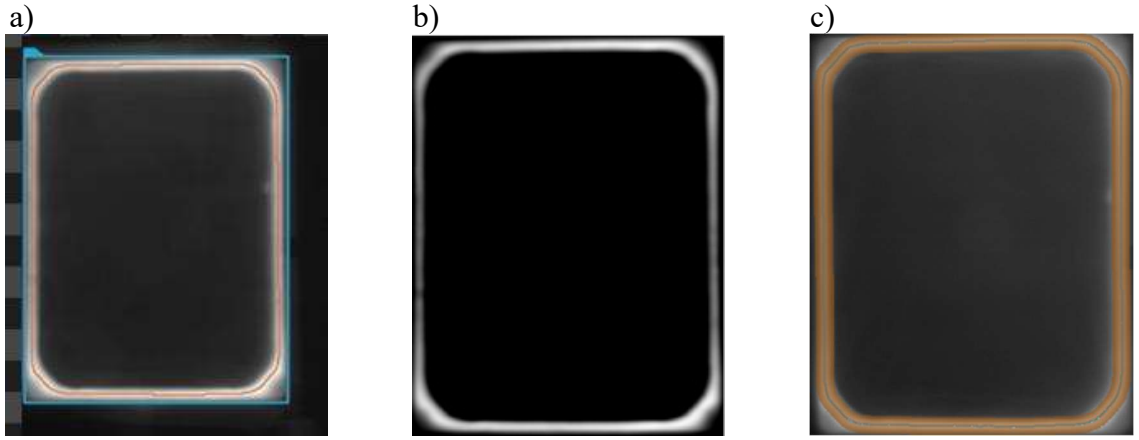
Rys. 55. Obraz IR a) po konwersji do formatu 8-bitowego b) po operacji rektyfikacji

W opracowanym algorytmie do detekcji obszaru inspekcji wykorzystano wiedzę o procesie technologicznym, zgodnie z którą najwyższa temperatura rejestrowana na obrazach odpowiada centralnej części obszaru zgrzewu. Na wykresie poniżej (Rys. 56) przedstawione zostały profile jasności w osi horyzontalnej oraz wertykalnej obrazów po uprzednim obrocie o kąt 90 stopni.



Rys. 56. Profil jasności w osi poziomej (kolor zielony) i pionowej (kolor niebieski)

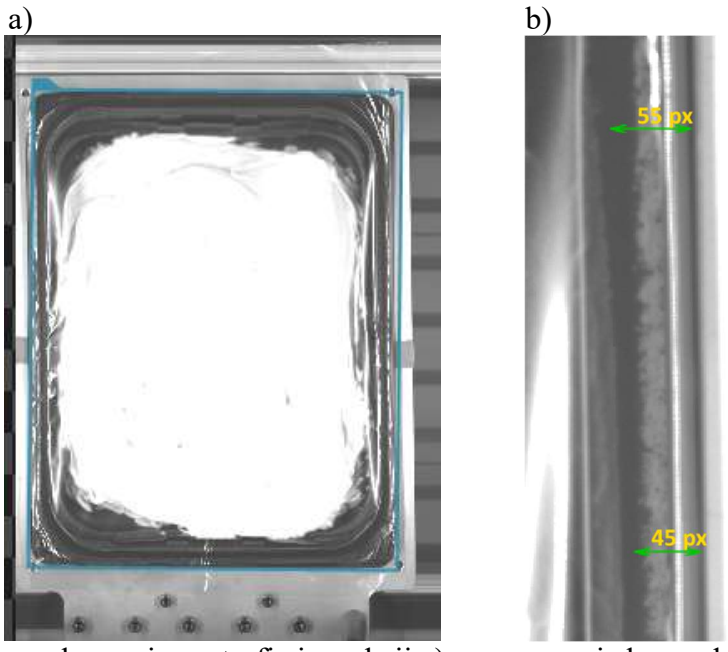
W analizowanych obszarach zgrzewu obserwuje się wyraźne lokalne maksima wartości jasności pikseli, odpowiadające położeniu geometrycznego środka zgrzewu. Na zarejestrowanym obrazie termowizyjnym widoczne są również różnice poziomów intensywności pikseli pomiędzy kierunkami analizy, jednak wartości w odpowiadających sobie lokalizacjach obszaru zgrzewu, analizowanych wzdłuż pojedynczej linii skanowania, pozostają porównywalne. Charakterystyka przestrzenna i kształt profilu jasności analizowanego obiektu umożliwiły zastosowanie algorytmu detekcji grzbietu (*ang. Ridge detection*) [177], który pozwala wyznaczyć pozycję i orientację całego obszaru zgrzewania (Rys. 57a). Po zastosowaniu odpowiedniego offsetu możliwe jest określenie obszaru ROI (*ang. Region of interest*) do którego ograniczony zostaje obraz wykorzystywany w dalszej analizie (Rys. 57b). Dodatkowo, wyznaczony zostaje obszar poszerzony względem pozycji środka profilu (Rys. 57c).



Rys. 57. Detekcja obszaru zgrzewania a) wynik algorytm Ridge (kolor czerwony) b) wyznaczony obszar ROI c) wyznaczony obszar ROI analizy zgrzewu

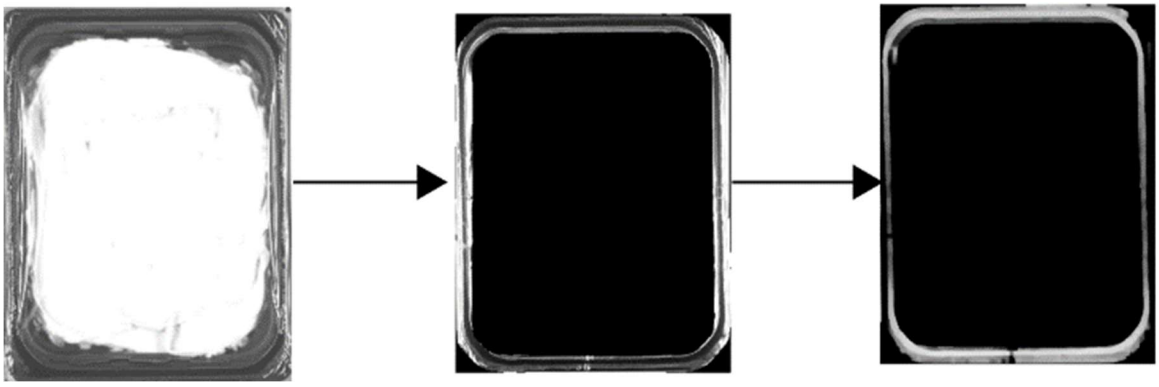
W efekcie wyodrębniony ROI obejmuje wyłącznie te fragmenty termogramu, które są istotne ze względu na operację fuzji obrazów. Ostatnim etapem procesu rejestracji obrazu IR jest dostosowanie jego rozdzielczości w taki sposób, aby była zgodna z rozdzielczością obrazu VIS.

Proces rejestracji obrazów pasma widzialnego rozpoczyna się od lokalizacji obiektu inspekcji. W tym celu mogą być zastosowane klasyczne rozwiązania jakimi są: algorytm detekcji krawędzi lub detekcję BLOB (*ang. Binary large object*). W obu przypadkach wykorzystywany jest wyraźny kontrast pomiędzy jaśniejszym tłem a opakowaniem (Rys. 58a), co zapewnia wysoką niezawodność oraz krótki czas przetwarzania. Należy podkreślić, że ze względu na luzy mechaniczne występujące podczas procesu zgrzewania, położenie strefy zgrzewu nie może zostać wyznaczone z wysoką dokładnością wyłącznie na podstawie zewnętrznego obrysu wykrytego opakowania. Odległość zewnętrznej krawędzi względem środka obszaru zgrzewania może ulegać znacznym zmianom nawet na krótkim odcinku, co prowadzi do lokalnych przesunięć geometrycznych i uniemożliwia precyzyjne określenie pozycji obszaru ROI (Rys. 58b). W celu wyznaczenia środka obszaru zgrzewania konieczne jest zastosowanie dodatkowych algorytmów umożliwiających dokładną lokalizację obszaru inspekcji w torze wizyjnych VIS.



Rys. 58. Detekcja opakowania w strefie inspekcji a) wyznaczenie krawędzi zewnętrznych opakowania b) różnica w pozycji środka obszaru zgrzewania względem krawędzi zewnętrznej

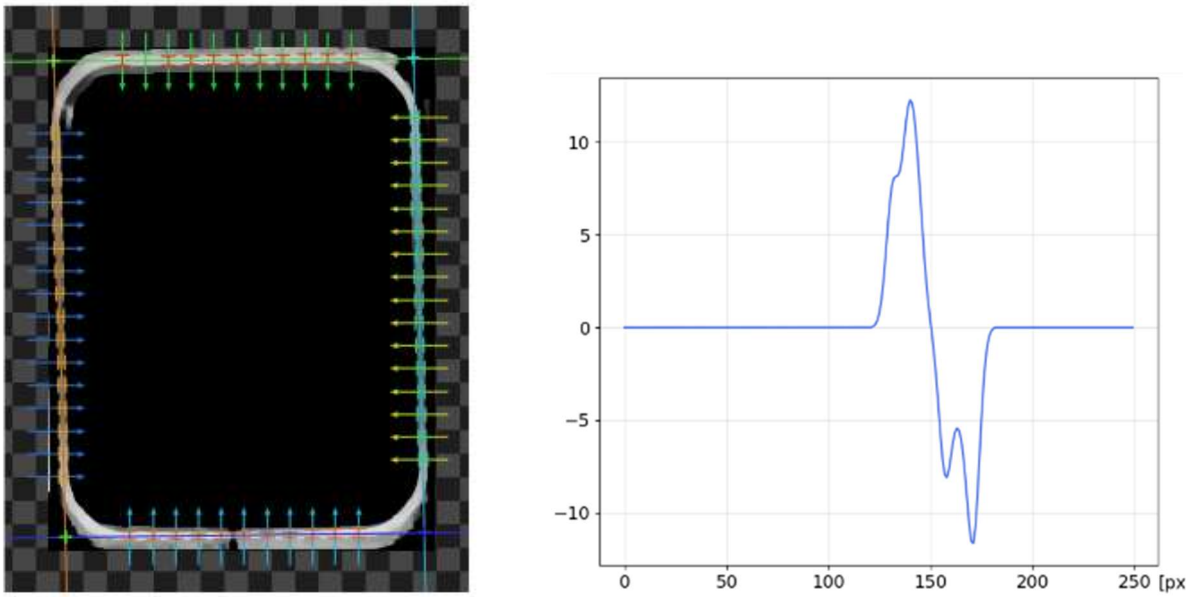
W pierwszej kolejności obraz jest poddany procesowi normalizacji w obszarze ROI wyznaczonym uprzednio podczas analizy obrazu IR. Następnie obraz VIS jest poddawany negacji oraz operacjom morfologicznym w celu wyeliminowania zbędnych artefaktów i wyizolowania strefy inspekcji (Rys. 59).



Rys. 59. Przetwarzanie obrazu VIS w celu uwydatnienia obszaru zgrzewania

Następnie, w predefiniowanych obszarach ROI stosowany jest algorytm detekcji pasm (*ang. stripe detection*) [177] (Rys. 60a). Pomimo, że etap wstępnego filtrowania redukuje ilość zakłóceń, nie eliminuje jednak wszystkich niepożądanych pików występujących w pochodnej profilu jasności (Rys. 60b). Z tego względu, aby zapewnić skuteczną detekcję pasm, konieczne jest odpowiednie dobranie parametrów algorytmu, w szczególności minimalnego progu amplitudy oraz dopuszczalnej szerokości pasma. Parametry te pozwalają odróżnić rzeczywiste krawędzie zgrzewu od lokalnych fluktuacji intensywności. Po wykryciu pasm, dla każdego z nich wyznaczany jest punkt centralny. Na podstawie zbioru tych punktów, poprzez interpolację liniową, generowane są cztery proste, które stanowią geometryczną rekonstrukcję obszaru zgrzewania.

a) b)

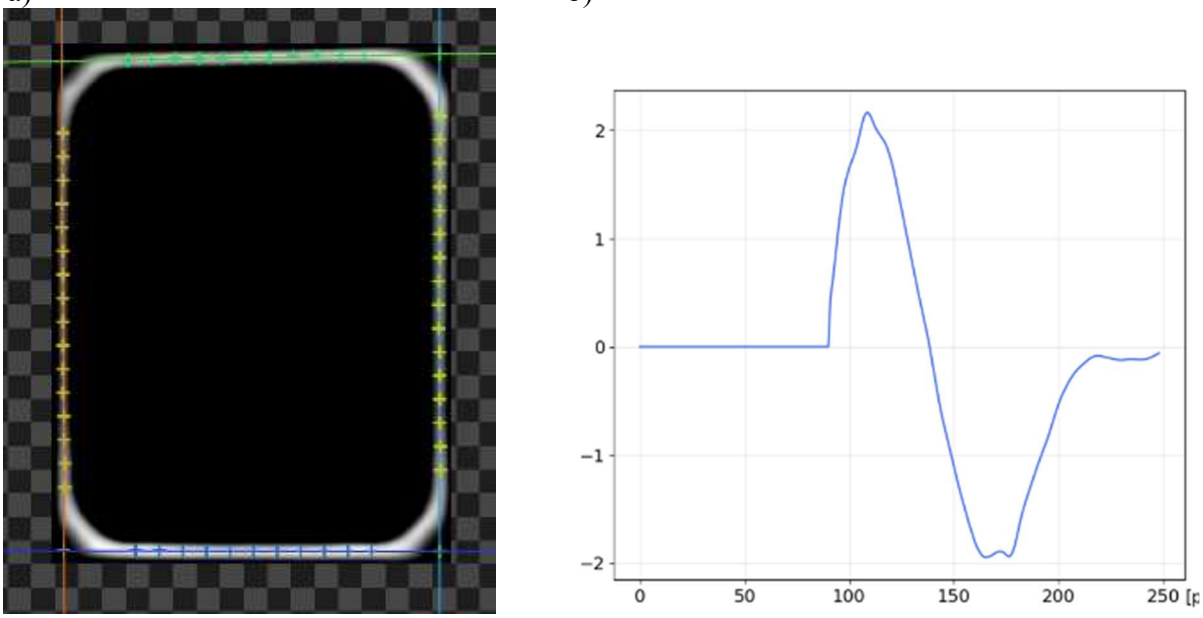


Rys. 60. Detekcja obszaru zgrzewania w paśmie VIS a) algorytm stripe detection b) przykładowy profil pochodnej poziomu jasności w obszarze skanowania

Punkty przecięcia wyznaczonych linii definiują następnie cztery naroża obszaru, który stanowi podstawę do dalszej analizy geometrycznej oraz rejestracji względem obrazu IR.

Ta sama procedura detekcji pasm jest następnie stosowana do obrazu IR, generując odpowiadające punkty narożne, które są następnie wykorzystywane do rejestracji obrazów (Rys. 61a). W tym przypadku analizowany profil, pozwala na jednoznaczne określenie środka pasma na podstawie pochodnej profilu jasności (Rys. 61b).

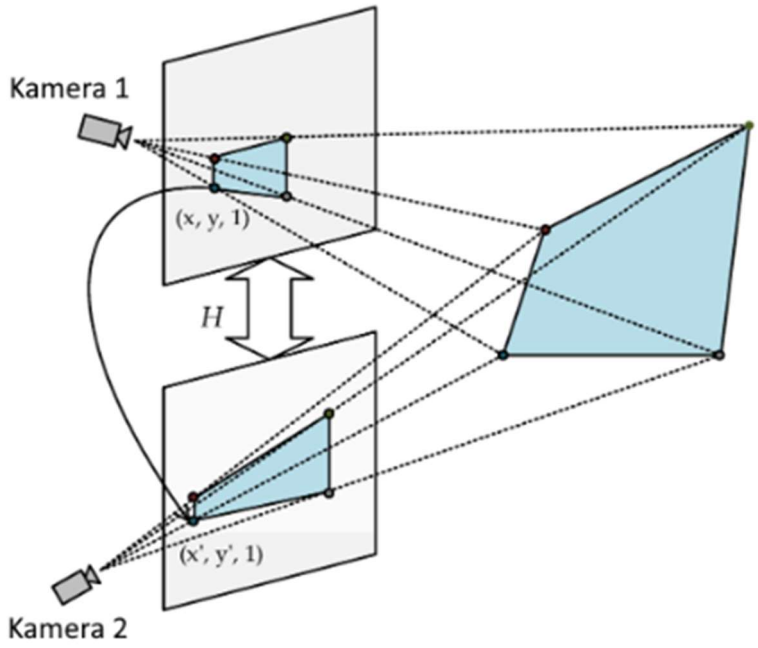
a) b)



Rys. 61. Detekcja obszaru zgrzewania w paśmie IR a) algorytm stripe detection b) przykładowy profil pochodnej poziomu jasności w obszarze skanowania

Zastosowany algorytm wykazuje wysoką odporność na lokalne nieciągłości analizowanego profilu, ponieważ granice obszaru są rekonstruowane na podstawie interpolacji liniowej wyznaczanej z wielu punktów charakterystycznych. Dodatkowo kontrolowane są kąty pomiędzy zrekonstruowanymi liniami, a w przypadku stwierdzenia istotnej odchyłki od kąta prostego, proces analizy zostaje przerwany, a rezultat inspekcji klasyfikowany jest jako negatywny.

W kontekście niedużej odległości obserwacji, płaskiej powierzchni i skutecznego usunięcia zniekształceń podczas wstępnego przetwarzania, do globalnej rejestracji obrazów zastosowano model projekcji perspektywicznej. Model ten gwarantuje zachowanie linii prostych w zarejestrowanych obrazach [178]. W celu zastosowania projekcji perspektywicznej konieczne jest wyznaczenie macierzy transformacji homograficznej $\boldsymbol{H}$ (Rys. 62)



Rys. 62. Model projekcji perspektywicznej [179]

Macierz homografii zdefiniowana jest w następujący sposób [179]:

$$\boldsymbol{H} = \begin{bmatrix} h_{11} & h_{12} & h_{13} \\ h_{21} & h_{22} & h_{23} \\ h_{31} & h_{32} & h_{33} \end{bmatrix} \tag{21}$$

gdzie:

$h_{12}, h_{12}, h_{21}, h_{22}$ - współczynniki transformacji afinicznej (rotacja, ścinanie),

h_{13}, h_{23} - translacja w przestrzeni obrazowej,

h_{31}, h_{32} - współczynniki projekcji perspektywicznej,

h_{33} - znormalizowany współczynnik skali.

Zależność opisującą przekształcenie współrzędnych pomiędzy odpowiadającymi sobie punktami obu obrazów można wyrazić następująco:

$$\begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = \boldsymbol{H} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \tag{22}$$

gdzie:

x, y - współrzędne punktu na obrazie 1.

x', y' - współrzędne punktu na obrazie 2.

Macierz homografii posiada osiem stopni swobody, wobec czego wyznaczenie czterech odpowiadających sobie par punktów w dwóch obrazach stanowi minimalny zestaw danych

niezbędnych do jej jednoznacznego określenia. Zaobserwowane transformacje między zarejestrowanymi obrazami próbek mają głównie charakter translacyjny i rotacyjny, bez istotnych nieliniowych deformacji. Do analizy dokładności modelu zastosowano metrykę odległości euklidesowej, powszechnie stosowaną w pomiarze różnic przestrzennych między odpowiadającymi sobie punktami, szczególnie w fuzji obrazów IR-VIS [180]. W tabeli 20 przedstawiono wyniki analizy błędów po przekształceniu obrazów dla referencyjnej pozycji narożników obszaru zgrzewania, uzyskane dla 125 par obrazów.

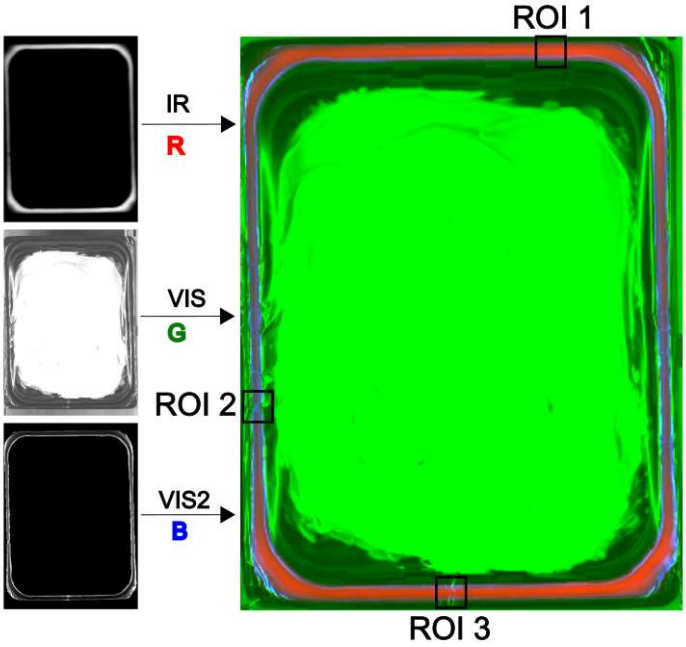
Tabela 20. Dokładność przekształcenia obrazów

	Odległość pomiędzy punktami [px]		
Punkt	Średnia	Odchylenie standardowe	Maksymalna
Prawy, górny narożnik	0,92	0,77	4,43
Lewy, górny narożnik	1,19	1,3	7,2
Dolny, prawy narożnik	0,99	0,74	4,47
Dolny, lewy narożnik	1,22	0,95	5,45

Wyznaczona dokładność przekształcenia mieści się w akceptowalnym zakresie. Przy rozdzielczości obrazowania kamery VIS wynoszącej 0,125 mm/px, uzyskiwana rozbieżność transformacji w większości analizowanych przypadków nie przekracza 0,5 mm. Uwzględniając przestrzenną rozdzielczość obrazowania kamery IR, przekraczającą 1 mm/px, osiągnięty poziom jest zgodny z oczekiwanymi wartościami wynikającymi z ograniczeń optycznych torów wizyjnych.

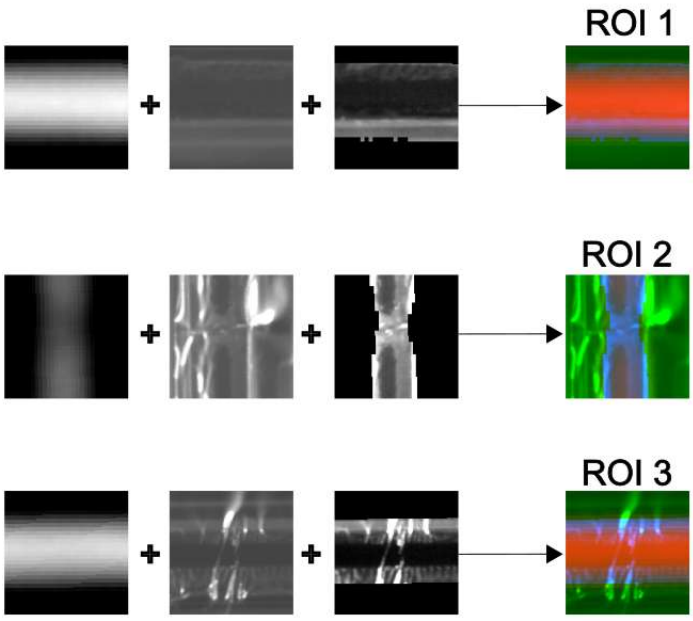
4.5. Metoda fuzji obrazów dla wysokowydajnych systemów inspekcji

Po usunięciu zniekształceń optycznych obrazy są rejestrowane i nakładane na siebie z wykorzystaniem opracowanego algorytmu detekcji punktów charakterystycznych, co umożliwia wygenerowanie pseudo-obrazu RGB. Proces fuzji pozwala na uzyskanie obrazu wynikowego, który integruje informacje o rozkładzie promieniowania cieplnego z pasma podczerwieni oraz wysokoczęstotliwościowe szczegóły tekstury z pasma widzialnego. W zaimplementowanym rozwiązaniu stosowana jest w tym celu metoda fuzji integrującą informacje pochodzące z obrazu termicznego oraz dwóch monochromatycznych obrazów w zakresie widzialnym: obrazu źródłowego i obrazu o zwiększonym kontraście w obszarze zgrzewania (Rys. 63). Otrzymany obraz może być następnie analizowany z wykorzystaniem metod uczenia maszynowego w celu detekcji i klasyfikacji wad.



Rys. 63. Obraz pseudo-RGB po operacji fuzji

Wyróżniony na obrazie górny obszar zainteresowania (ROI1) reprezentuje strefę o prawidłowych parametrach zgrzewania, co potwierdza jednorodny rozkład temperatury oraz brak defektów powierzchniowych. Z kolei obszar ROI2 wykazuje cechy charakterystyczne dla niedostatecznej temperatury procesu, skutkującej formowaniem się połączenia o obniżonej wytrzymałości. Dolny obszar (ROI3), mimo zarejestrowania odpowiedniej temperatury zgrzewania, ujawnia nieregularności struktury powierzchniowej folii w postaci zagnieceń. Opisane obszary przedstawione zostały na rysunku poniżej (Rys. 64).



Rys. 64. Przykładowe fragmenty zgrzewu na obrazie po operacji fuzji

Zastosowana metoda fuzji obrazu pseudo-RGB poprawia wizualizację defektów dla operatorów systemu. Dane termiczne przypisano do kanału czerwonego, wykorzystując naturalne skojarzenie tego koloru z wysoką temperaturą w percepcji człowieka. Informacje z zakresu światła widzialnego odwzorowano w kanale zielonym, natomiast obraz o podwyższonym kontraście przypisano do kanału niebieskiego. Takie podejście okazało się szczególnie skuteczne w uwydatnianiu defektów niskotemperaturowych, w przypadku których obniżona intensywność kanału czerwonego sprzyja wyraźniejszemu rozróżnieniu typów nieprawidłowości. Uzyskane w wyniku fuzji obrazy stanowią również wartościowe dane wejściowe dla algorytmów analizy obrazu, zwłaszcza w zastosowaniach wykorzystujących sztuczną inteligencję.

4.6. Algorytmy głębokiego uczenia detekcji i klasyfikacji defektów

Systemy wizyjnej inspekcji znajdują szerokie zastosowanie w aplikacjach przemysłowych. Ciągłe doskonalenie, modyfikacje i poszukiwanie nowych metod pomiarowych spowodowało olbrzymi postęp technologiczny w tym obszarze techniki zarówno pod względem rozwiązań sprzętowych jak również algorytmów przetwarzania i analizy obrazów. W ostatnich latach coraz częściej w zastosowaniach przemysłowych stosowane są metody sztucznej inteligencji, w tym szczególnie głębokie sieci neuronowe. Decyzja o wyborze pomiędzy klasycznymi algorytmami inspekcji (*ang. rule-based*), a metodami wykorzystującymi sztuczną inteligencję zależy m.in. od rodzaju aplikacji, wielkości zbioru przykładowych obrazów wyrobów oraz wymagań dotyczących wydajności. Tradycyjne algorytmy powinny być stosowane w takich zastosowaniach jak [181]:

- precyzyjne pomiary i kontrola wymiarów,
- lokalizacja, pozycjonowanie obiektów,
- analiza kolorów,
- odczyt kodów,
- wstępne przetwarzanie obrazów.

Algorytmy inspekcji wykorzystujące modele sieci neuronowych, w tym uczenie głębokie (*ang. deep learning*) oraz metody brzegowe (*ang. edge learning*) [182], sprawdzają się w złożonych zastosowaniach, gdzie konieczna jest identyfikacja defektów przy dużej zmienności występującej w rejestrowanych obrazach. Do najczęstszych aplikacji zaliczyć można:

- inspekcje wad powierzchniowych,
- detekcje i klasyfikacja obiektów lub defektów,
- detekcje anomalii,
- zaawansowane rozpoznawanie tekstu.

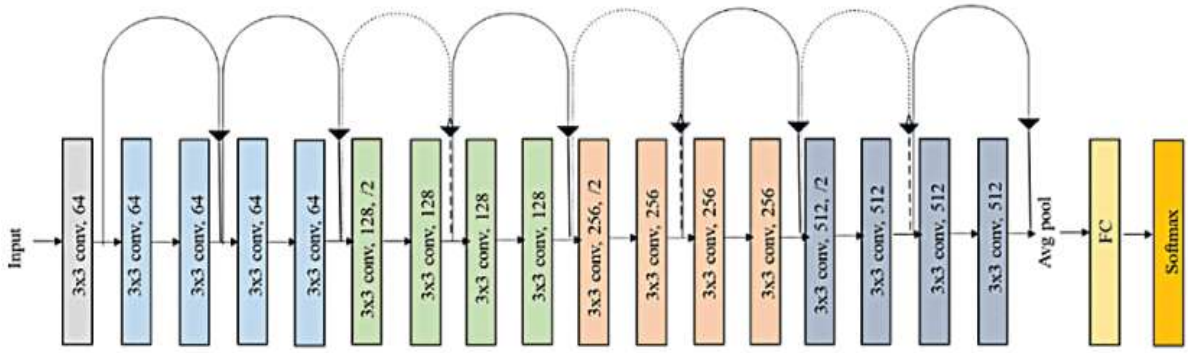
W celu przetestowania algorytmów uczenia głębokiego do inspekcji opakowań zgrzewanych termicznie, zastosowano technikę uczenia transferowego (*ang. transfer learning*).

Polega ona na adaptacji ostatniej warstwy modelu ogólnego zastosowania, wytrenowanego na bardzo dużej bazie danych, do realizacji konkretnego zadania klasyfikacji.

Klasyfikacja binarna

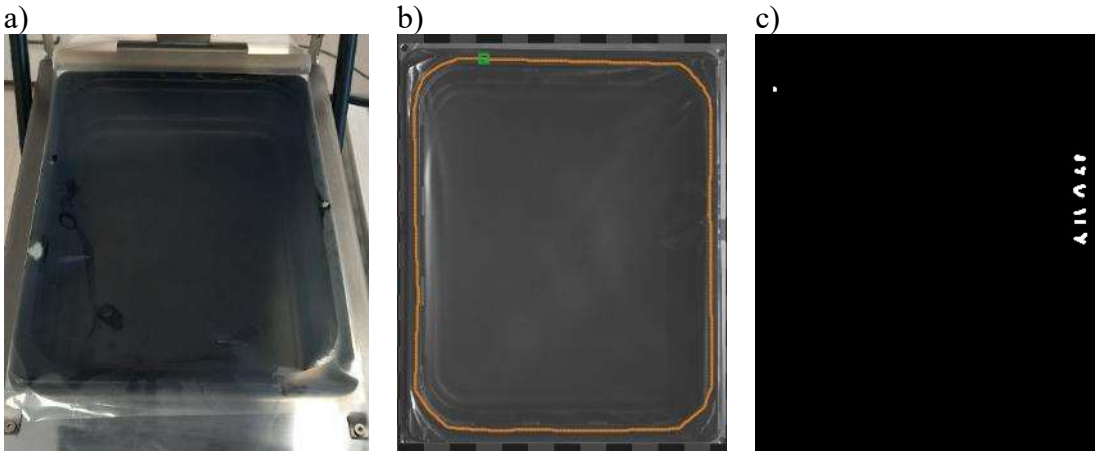
W pierwszym etapie prac opracowano potok przetwarzania danych (*ang. data pipeline*), którego celem było wytworzenie modelu klasyfikacji binarnej opakowań na dwie kategorie: produkty wadliwe i prawidłowo wykonane. Do tego celu wykorzystano obrazy z pasma widzialnego oraz model sieci ResNet-18, której architekturę przedstawiono na rysunku 65. Oryginalnie sieć ta została zaprezentowana przez autorów w 2015 roku, przy czym do jej wytrenowania wykorzystano wówczas zbiór danych ImageNet, zawierający 1000 klas obiektów i ponad milion zdjęć [183]. Tak duża liczba danych umożliwiła opracowanie modelu zdolnego do ekstrakcji różnorodnych cech i osiągnięcie niskiego poziomu błędu klasyfikacji.

Podczas badań nad zastosowaniem tej sieci do identyfikacji obrazów opakowań z wadami po procesie zgrzewania wykorzystano metodę uczenia transferowego. Jedyną modyfikacją wprowadzoną względem oryginalnej architektury była zmiana ostatniej warstwy, tak aby liczba rozpoznawanych klas została ograniczona do dwóch.



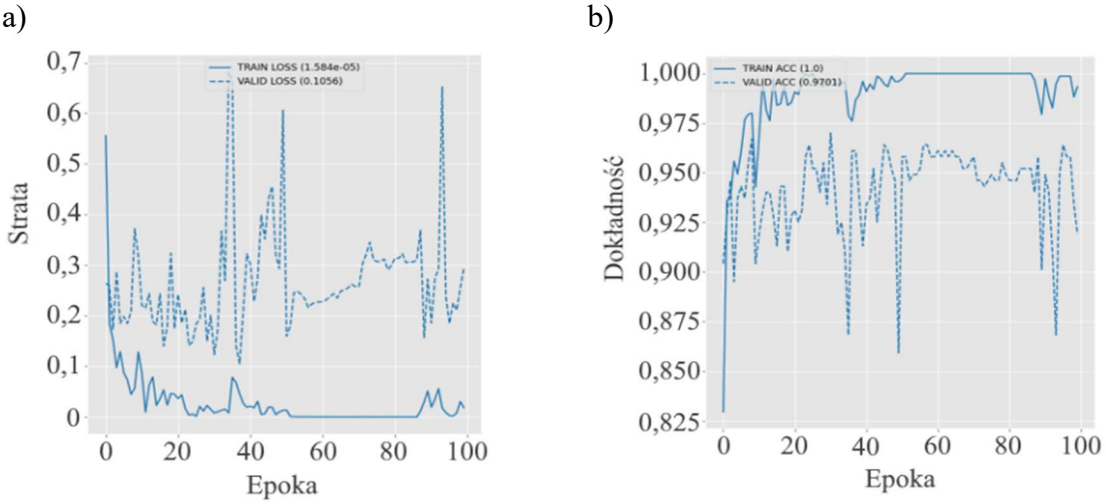
Rys. 65. Architektura modelu Resnet-18 [184]

W celu uzyskania obrazów do procesu uczenia sieci, wykorzystano manualną zgrzewarkę opakowań (Rys. 66a). Podczas zrealizowanych testów, obszar analizy został ograniczony jedynie do strefy zgrzewania. W tym celu określona została ścieżka (kolor pomarańczowy) (Rys. 66b) odpowiadająca obszarowi zgrzewania, która następnie została podzielona równomiernie na segmenty. W środku kolejnych segmentów, wyznaczony został obszar ROI o rozmiarze 64x64 pikseli. Przykładowy obszar inspekcji został zaznaczony kolorem zielonym. Dodatkowo wygenerowany został obraz maski na którym ręcznie zaznaczone zostały obszary defektów (Rys. 66c).



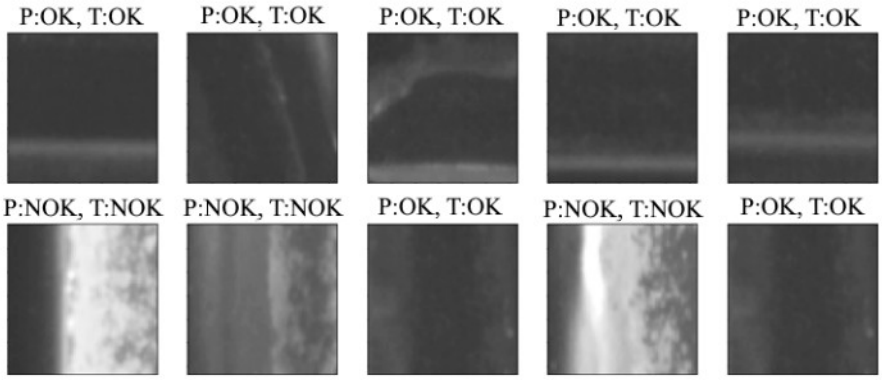
Rys. 66. Akwizycja obrazów a) przykładowa próbka przed zgrzewaniem b) obraz z kamery VIS z zaznaczonym obszarem ROI c) maska z zaznaczoną lokalizacja defektów w obszarze zgrzewania

W przypadku, gdy na obrazie maski w lokalizacji odpowiadającej obszarowi inspekcji ROI występująca liczba białych pikseli była wyższa od ustalonego limitu, obszar taki został zapisany w katalogu wad, oznaczonym jako „NOK". W przeciwnym przypadku obszar ROI został zapisany w katalogu oznaczonym jako „OK". Dzięki takiemu rozwiązaniu po jednej próbie zgrzewania możliwa była akwizycja od kilku do kilkunastu obszarów ROI z wadami oraz do kilkuset obrazów oznaczonych jako prawidłowe. Uzyskany zbiór obrazów podzielono na część przeznaczone do uczenia sieci neuronowej (735 obrazów) oraz na zbiór walidacyjny (334 obrazy). Łącznie w zbiorze danych było 463 obrazy sklasyfikowane jako „NOK" oraz 606 jako obrazy prawidłowego obszaru zgrzewu. Walidacja modelu podczas treningu polega na obliczeniu jego dokładności (*ang. accuracy*), definiowanej jako stosunek liczby poprawnych predykcji do wszystkich analizowanych obrazów. Jak można zaobserwować na wykresach przedstawiających proces uczenia (Rys. 67a), dokładność modelu już po kilku epokach przekroczyła 90%. Najwyższa uzyskana wartość wyniosła natomiast 97% dla danych walidacyjnych (Rys. 67b).



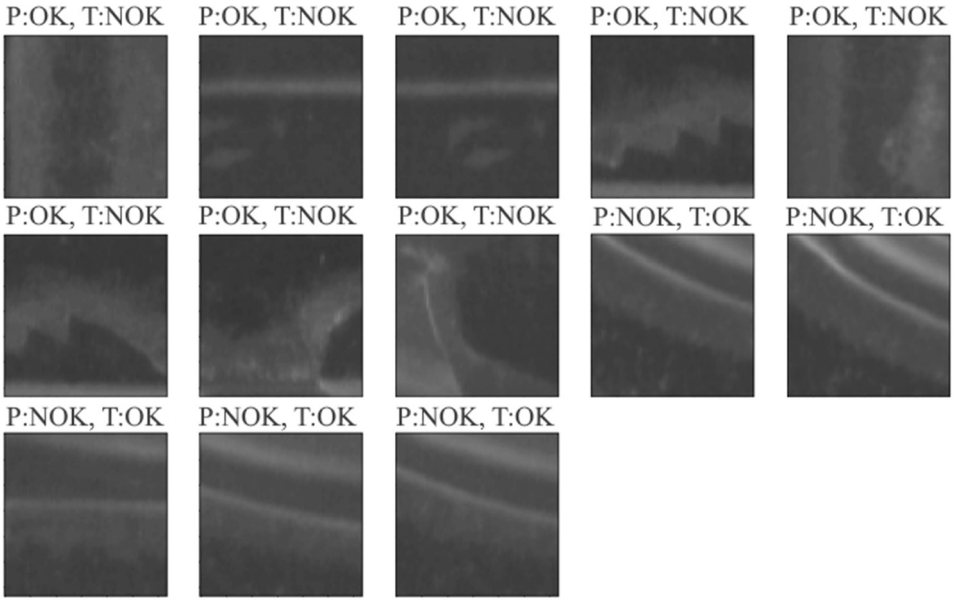
Rys. 67. Proces uczenia zmodyfikowanej sieci Resnet-18 a) wartość funkcji straty b) dokładność

Na grafice poniżej przedstawione zostały przykłady prawidłowo sklasyfikowanych obrazów wraz z wartościami prawdopodobieństwa przynależności do danej klasy (Rys. 68).



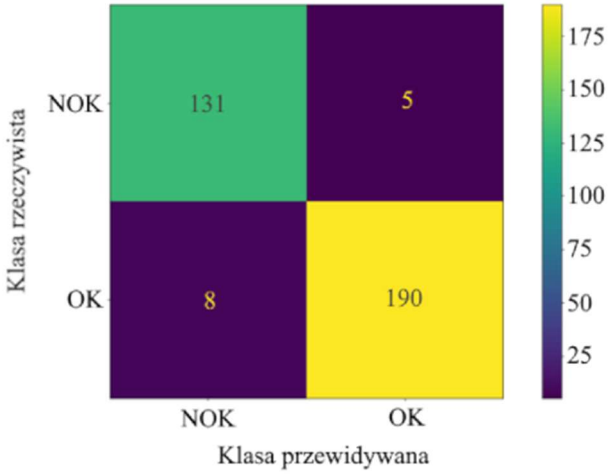
Rys. 68. Przykłady prawidłowo sklasyfikowanych obrazów

Nad każdym obrazem widoczne jest oznaczenie klasy określonej przez model - P (*ang. Predicted class*) oraz rzeczywistej klasy - T (*ang. True class*). Spośród obrazów testowych, jedynie 13 zostało nieprawidłowo sklasyfikowanych (Rys. 69). Należy zwrócić uwagę, że 5 ostatnich z przedstawionych próbek odpowiada obszarom narożników strefy zgrzewania, które stanowią stosunkowo niewielką część zbioru danych treningowych.



Rys. 69. Błędnie sklasyfikowane obrazy z wykorzystaniem opracowanego modelu.

Na rysunku 70 przedstawiono macierz błędów opracowanego modelu, wytrenowanego z wykorzystaniem metody transfer learning oraz obrazów zarejestrowanych po procesie zgrzewania.

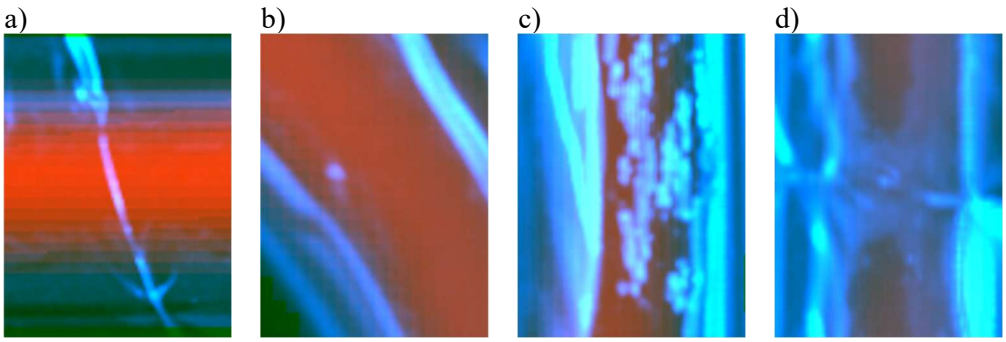


Rys. 70. Macierz błędów zmodyfikowanego modelu Resnet-18 dla klasyfikacji binarnej

Analiza macierzy błędów potwierdziła skuteczność detekcji wad powierzchniowych z wykorzystaniem metod głębokiego uczenia i obrazowania w paśmie widzialnym. Warto zaznaczyć, że skuteczność algorytmów detekcji powinna być jednak zweryfikowana na większej grupie testowej, wynoszącej kilka tysięcy obrazów. Istotną kwestią w tym przypadku jest uzyskanie odpowiedniej liczby próbek z wadami różnego typu, tak aby uniknąć problemu niezbalansowanego rozkładu danych uczących. W docelowej aplikacji istotne jest jednak nie tylko samo stwierdzenie obecności defektu, lecz także określenie jego kategorii.

Wykorzystanie modeli brzegowych do klasyfikacji wad

W kolejnym etapie prac zweryfikowano skuteczność klasyfikacji różnego rodzaju wad na podstawie obrazów wygenerowanych po procesie fuzji obrazów IR i VIS. W tym celu wykorzystano komercyjne oprogramowanie Zebra Aurora Deep Learning [175], które stanowi przykład zastosowania modeli brzegowych zoptymalizowanych do zastosowań w przemysłowych systemach inspekcji wizyjnej. Wygenerowane obrazy pseudo-RGB zostały poddane procesowy etykietowania wad z podziałem na cztery kategorie zagniecenia (Rys. 71a), zanieczyszczenia (Rys. 71b), zmarszczki (Rys. 71c) i słaby zgrzew (Rys. 71d).



Rys. 71. Przykładowe obrazy wad a) zagniecenie b) zanieczyszczenie c) zmarszczki d) słaby zgrzew

Do klasyfikacji wad zastosowano model sieci dedykowany do segmentacji obszarów zawierających określone cechy (*ang. feature detection*). Ze względu na wcześniejsze przygotowanie modeli przez producenta oprogramowania, konfiguracja architektury sieci jest możliwa jedynie w ograniczonym zakresie, poprzez zmianę następujących parametrów:

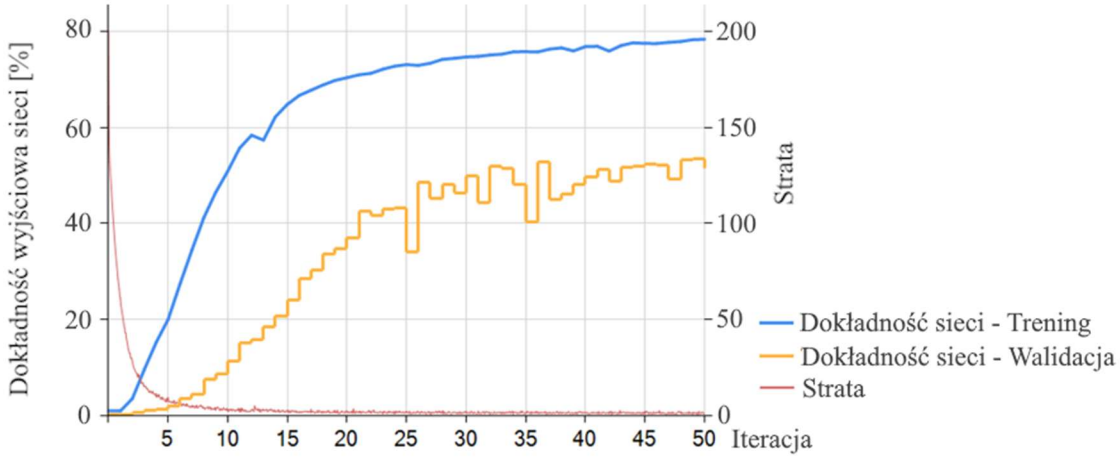
- głębokość sieci (*ang. Network depth*) - określa wybór predefiniowanej architektury o różnym poziomie złożoności,
- rozmiar okna (*ang. Patch size*) - parametr określający wymiary fragmentu obrazu, który jest jednorazowo analizowany przez sieć neuronową.

Ponadto, w celu zwiększenia ilości obrazów w zbiorze, możliwe jest zastosowanie operacji augmentacji, które obejmują następujące parametry:

- luminancja - zmiana jasności obrazów o losowy procent w przyjętym zakresie,
- kontrast - zmiana kontrastu poprzez mnożenie wartości pikseli o zadaną wartość,
- szum - wartość każdego piksela jest zmieniania niezależnie o losowy procent,
- rozmycie Gaussa - powoduje rozmycie obrazu za pomocą filtru o losowo wybranym rozmiarze (*ang. kernel size*) w przyjętym zakresie,
- rotacja - obrót próbki o losowy kąt z przyjętego zakresu,
- odbicie - generuje nowe obrazy przez odbicie względem wybranej osi,
- translacja - przesuwa obrazy o losowy wektor określany jako procent rozmiaru okna,
- skalowanie - zmienia rozmiar obrazów o losowy procent,
- deformacja skośna - pochylenie o losowy kąt z przyjętego zakresu.

Skuteczność detekcji i klasyfikacji wad z wykorzystaniem metod głębokiego uczenia zależy w dużym stopniu od wielkości zbioru danych wykorzystywanego podczas trenowania. Podczas realizacji prac badawczych baza danych obrazów była sukcesywnie powiększana. Na etapie badań wersji modelowej systemu inspekcji, proces uczenia sieci został przeprowadzony na zbiorze zawierającym 125 obrazów wygenerowanych po operacji fuzji, na których oznaczone zostały obszary zawierające wady. Dane zostały podzielone zgodnie z metodą *holdout* z losowym podziałem na trzy podzbiory (60-20-20) [185]: zbiór treningowy zawierający 75 obrazów, zbiór walidacyjny składający się z 25 obrazów oraz zbiór testowy obejmujący 25 obrazów. Zbiór walidacyjny został wykorzystany do optymalizacji modelu, natomiast zbiór testowy był zarezerwowany do końcowej ewaluacji modelu

W ramach zrealizowanych prac sprawdzone zostały różne konfiguracje parametrów sieci i augmentacji, wykorzystując metodę przeszukiwania siatki (*ang. Grid search*) [186]. Na rysunku 72 przedstawiono przykładowy przebieg procesu uczenia sieci. Dokładność modelu na danych treningowych już po około 20 epokach przekroczyła 70%, podczas gdy na zbiorze walidacyjnym była blisko dwukrotnie mniejsza. W kolejnych epokach model nie wykazywał znaczącej poprawy, co wskazuje, że nie był w stanie skutecznie rozpoznawać klas. Zaobserwowany brak dopasowania do danych treningowych oraz ograniczona zdolność generalizacji świadczą w tym przypadku o zjawisku niedouczenia (*ang. Underfitting*)



Rys. 72. Proces uczenia modelu klasyfikacji wad opakowań zgrzewanych termicznie

W celu zwiększenia ilości danych w bazie, zastosowane zostały operacje augmentacji, których parametry zostały przedstawione w tabeli 21.

Tabela 21. Parametry zastosowanych operacji augmentacji

Parametr	Wartość
Luminancja [%]	0,02
Kontrast [%]	0,02
Szum [%]	3
Rozmycie [%]	3
Rotacja [˚]	3
Skalowanie [%]	98÷102
Pochylenie horyzontalne [%]	1
Pochylenie wertykalne [%]	1

W zastosowanym oprogramowaniu wykorzystano kilka metryk do końcowej ewaluacji efektywności trenowanych modeli. Precyzja *P* (*ang. Precision*) - jest miarą jakości klasyfikacji, definiowaną jako stosunek liczby próbek zaklasyfikowanych przez model jako prawdziwie pozytywne (rzeczywiste wady) do liczby wszystkich próbek oznaczonych przez model jako pozytywne. Wartość tego wskaźnika wyrażona jest zależnością:

$$P = \frac{TP}{TP+F} \tag{23}$$

gdzie:

TP (ang. True Positive) - prawidłowo sklasyfikowane obszary wad,

FP (ang. False Positive) - nieprawidłowo sklasyfikowane obszary bez wad.

Czułość *R* (*ang. Recall*) - jest miarą kompletności klasyfikacji, definiowaną jako stosunek liczby próbek poprawnie zaklasyfikowanych przez model jako prawdziwie pozytywne (TP) do liczby wszystkich próbek oznaczonych jako pozytywne. W przypadku omawianego systemu

inspekcji są to wszystkie obszary z oznaczonymi wadami. Wartość tego wskaźnika wyrażona jest zależnością:

$$R = \frac{TP}{TP+FN} \tag{24}$$

gdzie:

FN (ang. False Negative) - błędnie sklasyfikowane lub niewykryte obszary wad.

Metryka F1-score stanowi średnią harmoniczną precyzji i czułości, zapewniając zrównoważoną ocenę jakości klasyfikacji. Wartość tego wskaźnika wyrażona jest zależnością:

$$F1 = \frac{2 \cdot P \cdot R}{P+R} \tag{25}$$

Metryka ta jest szczególnie przydatna w analizie modeli uczonych na zbiorach o istotnej nierównowadze klas, gdzie sama dokładność może prowadzić do błędnych wniosków.

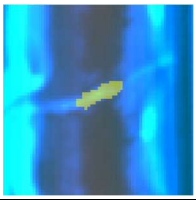
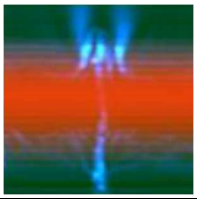
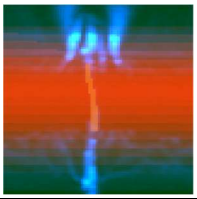
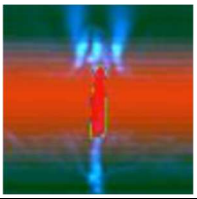
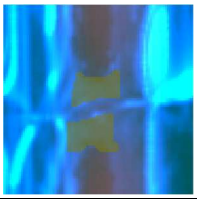
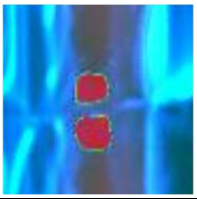
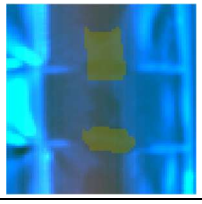
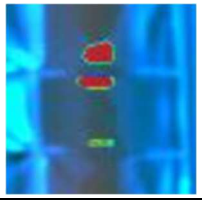
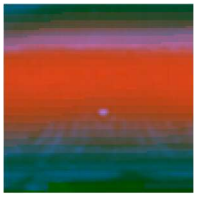
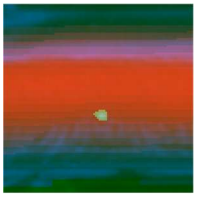
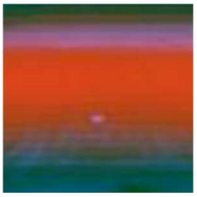
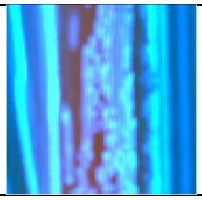
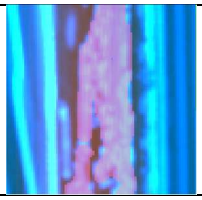
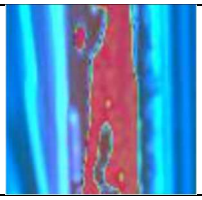
Opracowany model, umożliwił klasyfikację wad obejmujących zagniecenia, zmarszczki, słaby zgrzew oraz zanieczyszczenia w strefie zgrzewania. Uzyskane wyniki ewaluacji zostały przedstawione w tabeli 22.

Tabela 22. Ewaluacja opracowanego modelu klasyfikacji wad

Metryka	Dane treningowe	Dane testowe
F1-score [%]	86,4	67,9
Czułość [%]	89,4	65,7
Precyzja [%]	83,7	70,3

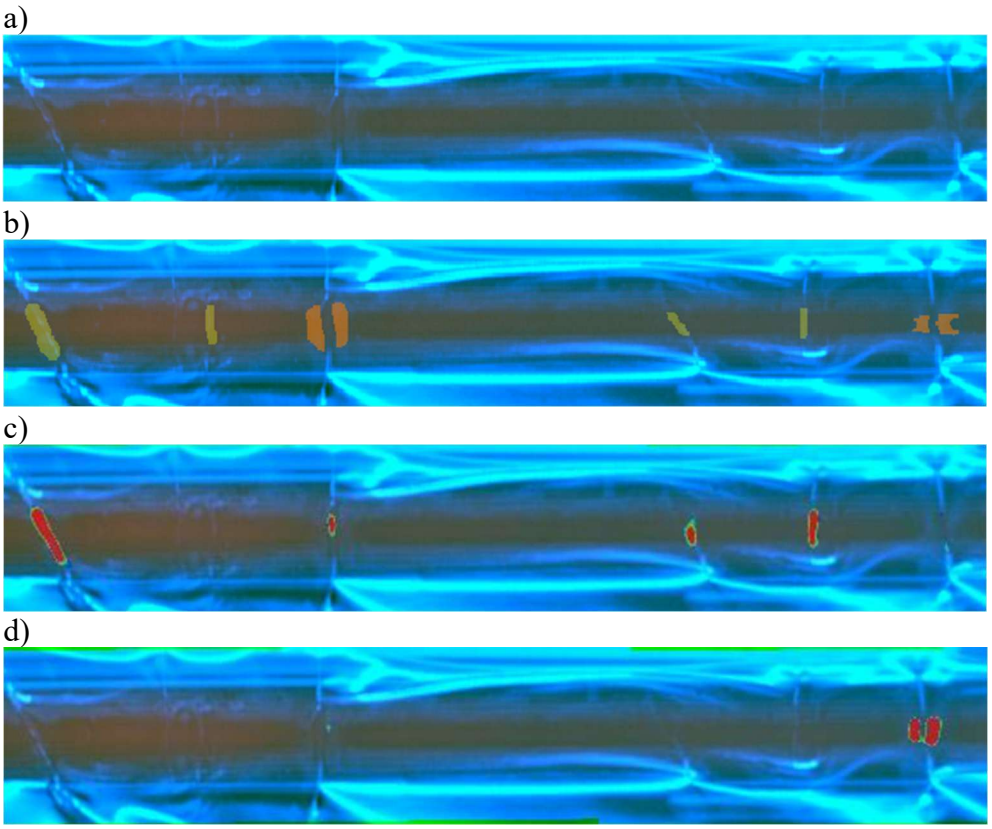
Pomimo relatywnie niedużego zbioru danych, na podstawie uzyskanych wyników, można stwierdzić, że wygenerowane obrazy pseudo-RGB dostarczają cennych danych nie tylko do wykrywania defektów, ale także szczegółowej klasyfikacji. W tabeli 23 przedstawione zostały przykładowe rezultaty analizy uzyskane z wykorzystaniem opracowanego modelu, które zaprezentowane zostały w postaci map prawdopodobieństwa występowania defektu danej klasy. W celu zapewnienia pełnej reprezentacji danych uwzględniono również oryginalny obraz oraz obszar etykiet wykorzystanych na etapie trenowania sieci. Jak można zaobserwować, specyfika defektów widocznych na zarejestrowanych obrazach znacząco utrudnia precyzyjne wyznaczenie granic obszarów podczas procesu etykietowania. Defekty w postaci zagnieceń są prawidłowo rozpoznawane zarówno w obszarach o niskiej temperaturze (Wada nr 1), jak i w obszarach o temperaturze podwyższonej (Wada nr 2). W przypadku wady słabego zgrzewu (Wada nr 3) częste jest jednoczesne występowanie w tym samym regionie zagniecenia.

Tabela 23. Przykładowe rezultaty klasyfikacji obszarów defektów dla danych walidacyjnych

Nr	Typ wady	Obraz oryginalny	Obszar etykiety	Mapa prawdopodobieństwa
1	Zagniecenie			
2	Zagniecenie			
3	Słaby zgrzew			
4	Słaby zgrzew			
5	Zanieczyszczenie			
6	Zmarszczki			

Warto zaznaczyć, że przy niskim kontraście defektu wskazywane prawdopodobieństwo wystąpienia wady pozostaje relatywnie niskie (Wada nr 4). Opracowany model wykazuje również ograniczoną skuteczność w rozpoznawaniu niewielkich zanieczyszczeń (Wada nr 5). Natomiast w przypadku rozległych defektów typu zmarszczki trudność stanowi poprawne wyznaczenie obszaru wady na granicy zgrzewu (Wada nr 6).

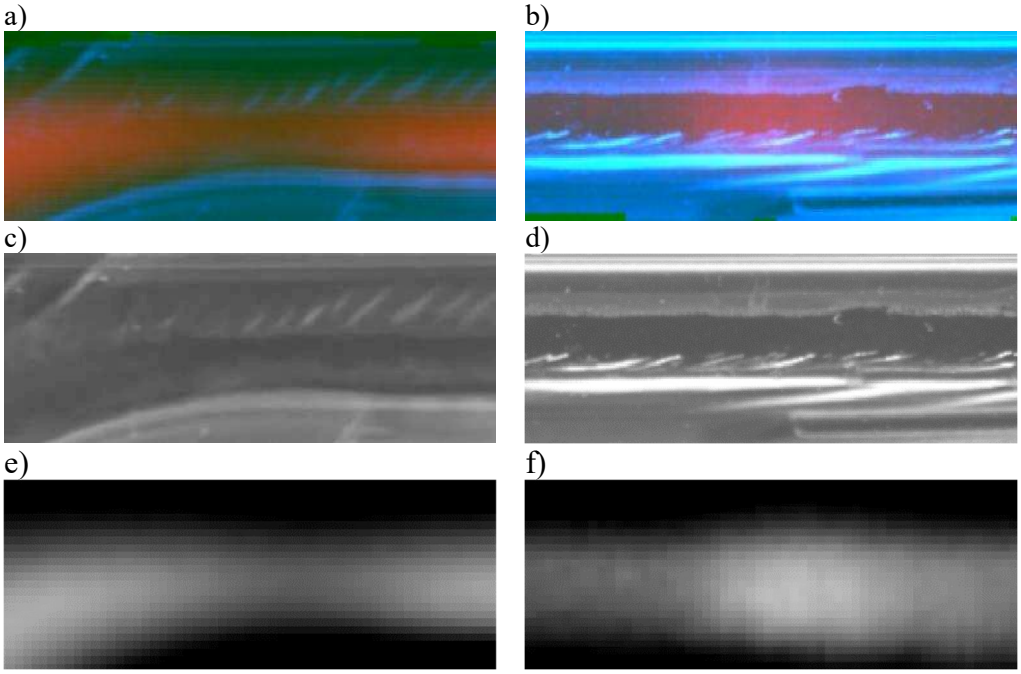
Dla danych testowych, które nie były wykorzystywane podczas treningu, model wykazuje umiarkowaną skuteczność detekcji i klasyfikacji wad. Na rysunkach poniżej przedstawiony został przykładowy fragment obrazu (Rys. 73a), wykonane oznaczenia obszarów defektów (Rys. 73b) oraz rezultaty inspekcji w postaci map prawdopodobieństwa dla defektów w postaci zagniecenia (Rys. 73c) oraz słabego zgrzewu (Rys. 73d).



Rys. 73. Przykładowe dane ze zbioru testowego a) obraz oryginalny b) etykiety wad w postaci zagięcia (kolor żółty) i słabego zgrzewu (kolor pomarańczowy) c) detekcja zagięcia d) detekcja słabego zgrzewu

Jak można zaobserwować w przypadku wad o niskim kontraście może wystąpić problem braku konsekwencji i powtarzalności przy procesie etykietowania. Efektem tego są pominięte całkowicie przez model drobne zagięcia w lewej części przedstawionego fragmentu obrazu. Ma to szczególne znaczenie w przypadku niewielkich zbiorów danych, gdzie pojedyncze błędy osoby etykietującej mogą istotnie wpłynąć na wyniki ewaluacji modelu. Z drugiej strony należy podkreślić, że opracowany model nie wykazuje tendencji do generowania fałszywych alarmów, czyli błędnej klasyfikacji prawidłowych obszarów zgrzewu jako wad. W warunkach przemysłowych zjawisko to mogłoby prowadzić do nadmiernej liczby odrzuconych wyrobów, a w konsekwencji do strat lub konieczności przeprowadzenia dodatkowej, manualnej kontroli dużej partii produkcyjnej. Ustalenie właściwego kompromisu pomiędzy czułością modelu a jego precyzją stanowi jedno z kluczowych zagadnień podczas wdrażania systemu w rzeczywistych warunkach pracy.

Ze względu na niewielką liczbę próbek, podczas prac nad modelem klasyfikacji nie zostały utworzone kategorie wad w postaci lokalnego wzrostu (Rys. 74a) i obniżenia (Rys. 74b) temperatury w obszarze zgrzewania. W obszarach zaznaczonych na rysunkach nie występują wyraźne zmiany powierzchniowe na obrazach pasma VIS, które mogłyby sugerować zmianę w emisyjności (Rys. 74 c,d). Na zarejestrowanych termogramach można jednak zaobserwować znaczące anomalie (Rys. 74 e,f).



Rys. 74. Przykłady anomalii w profilu temperaturowym zgrzewu a) obraz 1 pseudo-RGB b) a) obraz 2 pseudo-RGB c) obraz 1 VIS d) obraz 2 VIS e) obraz 1 IR f) obraz 2 IR

Przedstawione przykłady potwierdzają komplementarny charakter zaproponowanej hybrydowej metody inspekcji. W opisanej wcześniejszej ewaluacji modelu wykazano również, że metoda ta generuje informacje o charakterze redundantnym, co zwiększa niezawodność klasyfikatora. Połączona analiza obu źródeł danych może natomiast dostarczyć nowej, pogłębionej wiedzy na temat procesu zgrzewania opakowań.

Modele głębokich sieci neuronowych do klasyfikacji wad

W kolejnym etapie realizacji projektu przeprowadzono badania skuteczności detekcji wad z wykorzystaniem modeli głębokiego uczenia o charakterze ogólnego zastosowania, które nie były trenowane na obrazach zarejestrowanych przez przemysłowe systemy inspekcji. Metody głębokiego uczenia znalazły zastosowanie w różnych obszarach, takich jak autonomiczna jazda, robotyka oraz monitoring wizyjny. Podjęto również liczne próby zastosowania metod opartych na głębokich sieciach neuronowych w systemach inspekcji przemysłowej. Do najczęściej stosowanych modeli zaliczyć można m.in. sieci RCNN, EfficientDet [187]

oraz RT-DETR [188]. Do rozwiązywania zadań detekcji obiektów wykorzystane są różne architektury, które można podzielić na modele dwuetapowe (*ang. two-stage detectors*) oraz jednoetapowe (*ang. one-stage detectors*). Pierwsze z nich wymagają wstępnej detekcji regionów (*ang. Region proposal*), w których mogą znajdować się obiekty, a następnie wykonują ich klasyfikację (Rys. 75a). W podejściu jednoetapowym oba te zadania realizowane są równocześnie w module wyjściowym (*ang. head network*) (Rys. 75b).

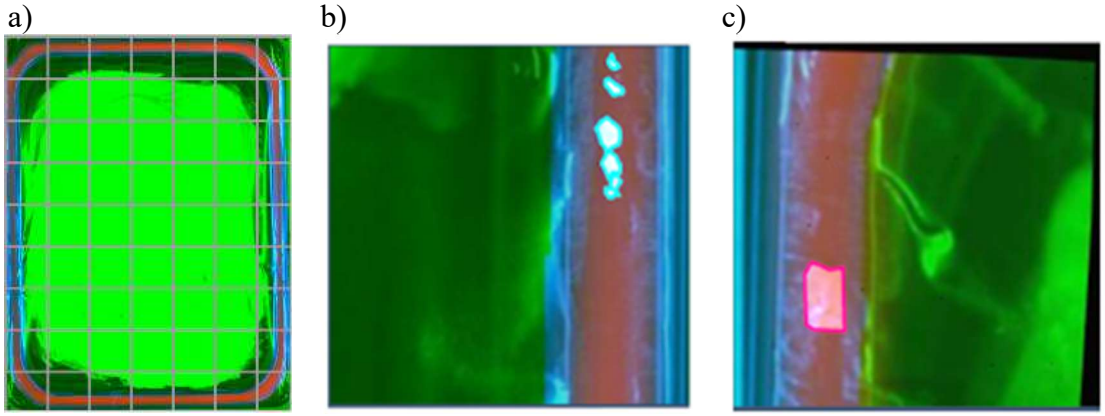


Rys. 75. Architektura sieci a) dwuetapowa b) jednoetapowa [189]

Wśród najbardziej przełomowych modeli jednoetapowych stosowanych do detekcji i klasyfikacji obiektów znajduje się YOLO (*ang. You Only Look Once*) [190]. Rozwiązanie to jest powszechnie wskazywane jako preferowany wybór w badaniach wstępnych oraz analizach koncepcyjnych, ze względu na wysoką zdolność uogólniania modeli oraz efektywność obliczeniową. W ostatnich latach opracowano wiele wariantów YOLO do detekcji obiektów, które zdołały połączyć wysoką skuteczność wykrywania z dużą szybkością działania. Wybór odpowiedniej architektury YOLO sprowadza się do znalezienia równowagi między dokładnością i wydajnością obliczeniową. W praktyce wcześniejsze modele do wersji 8 sprawdzają się w zadaniach wymagających pracy w czasie rzeczywistym, natomiast nowsze implementacje osiągają większą precyzję wykrywania defektów. Zaproponowana w 2025 roku wersja YOLO-v12 osiąga najwyższy poziom efektywności, w porównaniu z poprzednimi wersjami, przy jednoczesnym zachowaniu bardzo dużej szybkości [191]. Przeprowadzone badania potwierdziły skuteczność tej architektury również w zastosowaniach związanych z przemysłowymi systemami kontroli jakości.

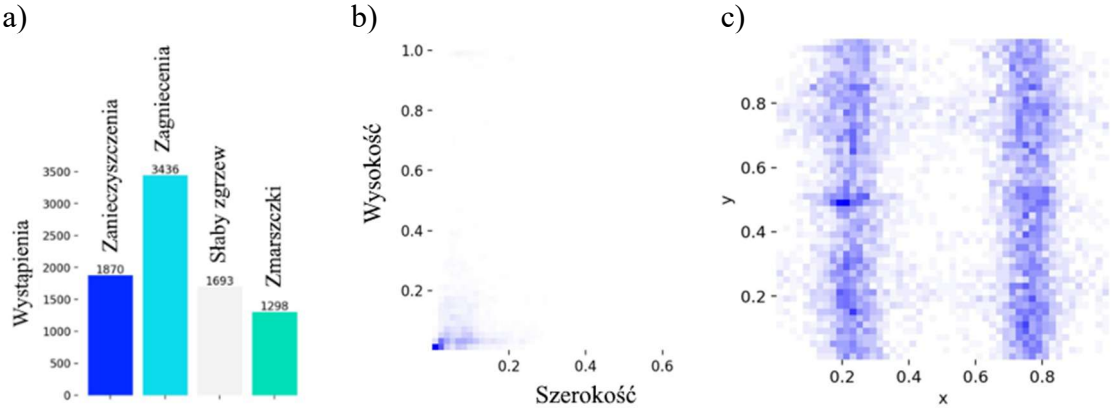
Do utworzenia i zarządzania bazą danych wykorzystano platformę Roboflow [192], która umożliwia wykonywanie zaawansowanych operacji augmentacji oraz bezpośredniego trenowania modeli w chmurze obliczeniowej. Przygotowany zbiór danych zawierał niemal 200 wysokiej rozdzielczości obrazów po operacji fuzji. Wykrywane typy defektów obejmowały cztery kategorie, do których przypisano 1926 etykiet (średnio 9,7 na obraz). W celu zwiększenia efektywności procesu treningu sieci oraz wyodrębnienia istotnych obszarów zgrzewu, podczas wstępnego przetwarzania zastosowana została metoda dzielenia obrazów na mniejsze fragmenty (Rys. 76a). Zbiór surowych danych (*ang. Raw image dataset*) (Rys. 76b) został

ponadto rozszerzony przy użyciu klasycznych metod augmentacji danych (Rys. 76c). Zastosowane zostały następujące transformacje: losowa rotacja (od -5° do +5°), losowe odbicie (poziome, pionowe) oraz pochylanie (*ang. shear*) (±2° poziomo, ±2° pionowo). Dodatkowo zastosowano zmianę jasności obrazu w zakresie od -2% do +2%, a także dodano szum na poziomie do 0,1% pikseli. W ten sposób wygenerowanych zostało blisko 12500 nowych obrazów, których rozdzielczość wynosiła 212×220.



Rys. 76. Przygotowanie bazy danych a) podział obrazu źródłowego b) przykładowy obraz c) obraz po przykładowy procesie augmentacji

Dodatkowo odfiltrowano 70% obrazów, które nie zawierały żadnych etykiet. Po tej operacji ostateczna liczba obrazów w zbiorze wyniosła 6075. Na wykresach poniżej przedstawione zostały szczegółowe statystyki dotyczące podziału liczby etykiet na klasy (Rys. 77a), znormalizowanego rozmiaru (Rys. 77b) oraz lokalizacji wad (Rys. 77c).



Rys. 77. Statystyki etykiet: a) liczba adnotacji dla danej klasy b) rozmiar c) położenie etykiet

Podczas badań eksploracyjnych przetestowano modele oparte na konwolucyjnych sieciach neuronowych (CNN), takie jak YOLO-v12 i YOLO-v8, oraz model RT-DETR, który stanowi przykład podejścia wykorzystującego koncepcję Vision Transformers.

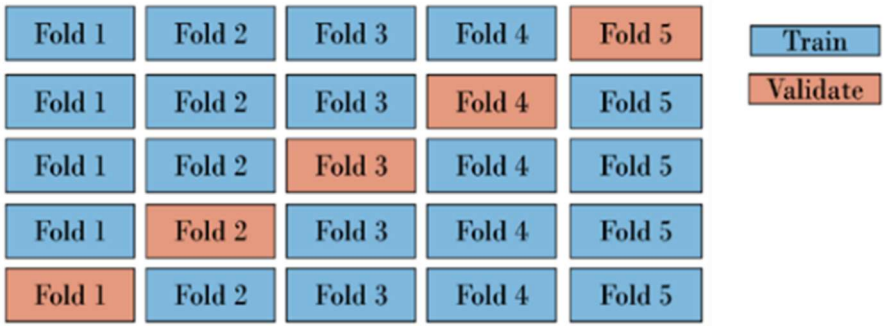
Do ewaluacji modeli posłużono się dodatkowymi metrykami. Średnia precyzja AP (*ang. Average precision*) jest definiowana jako obszar pod krzywą precyzja–czułość. Metryka mAP (*ang. Mean Average precision)* jest wyznaczana poprzez obliczenie wartości AP

dla każdej klasy osobno, a następnie ich uśrednienie. Wskaźnik IoU (*ang. Intersection over Union*) mierzy obszar wspólny przewidywanego regionu obiektu i rzeczywistego obszaru. Dwiema popularnymi metrykami dla modeli detekcji obiektów, które zapewniają kompleksowy obraz wydajności modelu na różnych poziomach trudności detekcji są [18]:

- mAP50: średnia precyzja, obliczana przy progu 0,50 IoU,
- mAP50–95: mAP, obliczana w krokach co 0,05 od 0,50 do 0,95 IoU.

W zadaniu segmentacji struktura YOLO zwraca dwie główne metryki podczas oceny: mAP (Box), która mierzy precyzję wykrywania i lokalizowania obiektów za pomocą prostokątów ograniczających obiekty, oraz mAP (Mask), która określa skuteczność modelu w rozpoznawaniu i reprezentowaniu szczegółowych kształtów obiektów za pomocą masek segmentacji. Model RT-DETR jest przeznaczony do klasycznej detekcji obiektów więc jako rezultat zwraca jedynie wartość mAP (Box).

Ze względu na ograniczony rozmiar zbioru danych użytego do oceny modelu zastosowano procedurę pięciokrotnej walidacji krzyżowej [193]. Zbiór danych podzielono na pięć wzajemnie wykluczających się podzbiorów (*ang. Fold*) z losowo wybranymi próbkami. Każdy model trenowano pięć razy, za każdym razem wykorzystując inny podzbiór jako dane walidacyjne, a pozostałe cztery jako dane treningowe (Rys. 78).



Rys. 78. Podział danych w metodzie pięciokrotnej walidacji krzyżowej [193]

Eksperymenty przeprowadzono z użyciem jednolitego zestawu hiperparametrów, w tym:

- liczba epok - 150,
- rozdzielczość obrazu wejściowego - 224,
- wielkość partii (*ang. batch size*) - 32,
- początkowa wartość współczynnika uczenia (*ang. learning rate*) (lr0): 1×10^{-3},
- optymalizator SGD,
- współczynnik regularyzacji (*ang. weight decay*): 5×10^{-4}.

W badaniach wykorzystano framework Ultralytics [194], przeznaczony do trenowania, walidacji i wdrażania modeli YOLO. Narzędzie to umożliwia również obsługę innych architektur, co pozwala na ich bezpośrednie porównanie. W testach użyte zostały modele YOLO-v12 oraz RT-DETR. Uzyskane rezultaty ewaluacji przedstawione zostały w tabeli 24.

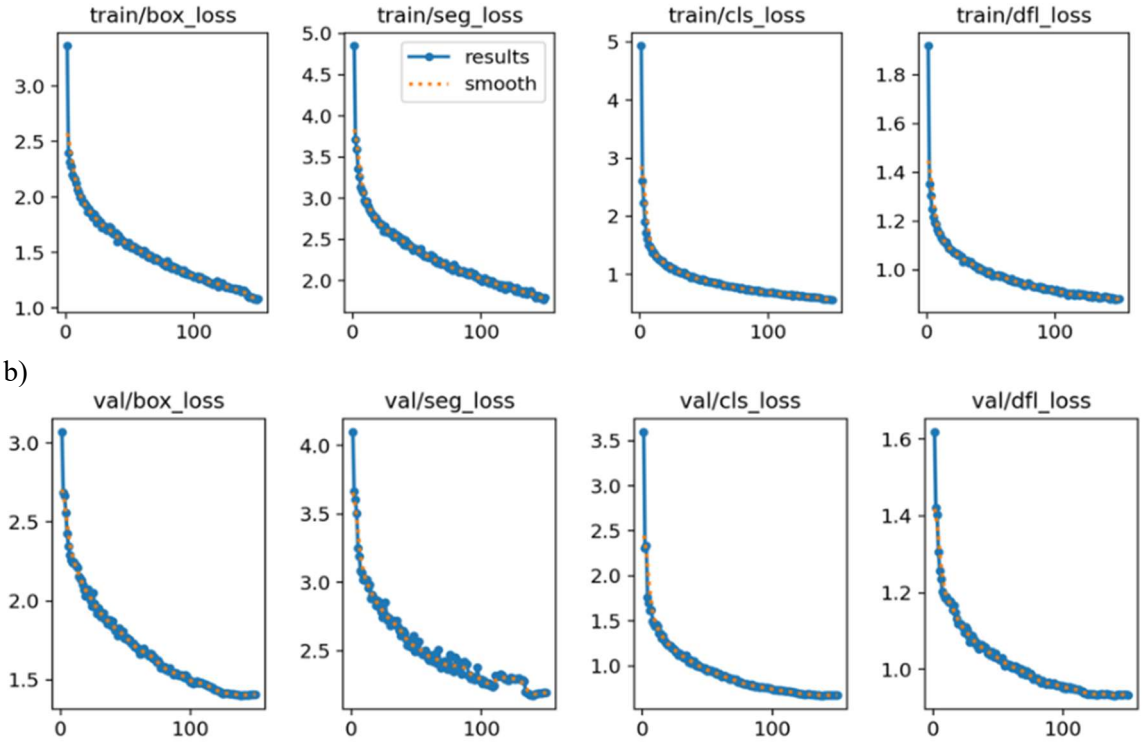
Tabela 24. Porównanie modeli YOLO i RT-DETR

Model	Rozmiar	mAP50 (Box)	mAP50-95 (Box)
YOLO-v12	l-large	0,704	0,413
RT-DETR	l-large	0,703	0,363

Dla obu modeli uzyskano zbliżone wyniki w metryce mAP50. W przypadku bardziej wymagających próbek wad model YOLO wykazał wyższą skuteczność, osiągając wynik mAP50–95 wyższy o 5 punktów procentowych w porównaniu z modelem RT-DETR. Na podstawie przeprowadzonych analiz do dalszych prac wybrano model YOLO v12. W celu oceny wpływu rozmiaru architektury na dokładność klasyfikacji wad, przeprowadzono trening wszystkich dostępnych wariantów. Na wykresach przedstawiony został przykładowy proces uczenia sieci w wariancie Extra-large, dla danych treningowych (Rys. 79a) oraz danych walidacyjnych (Rys. 79b).

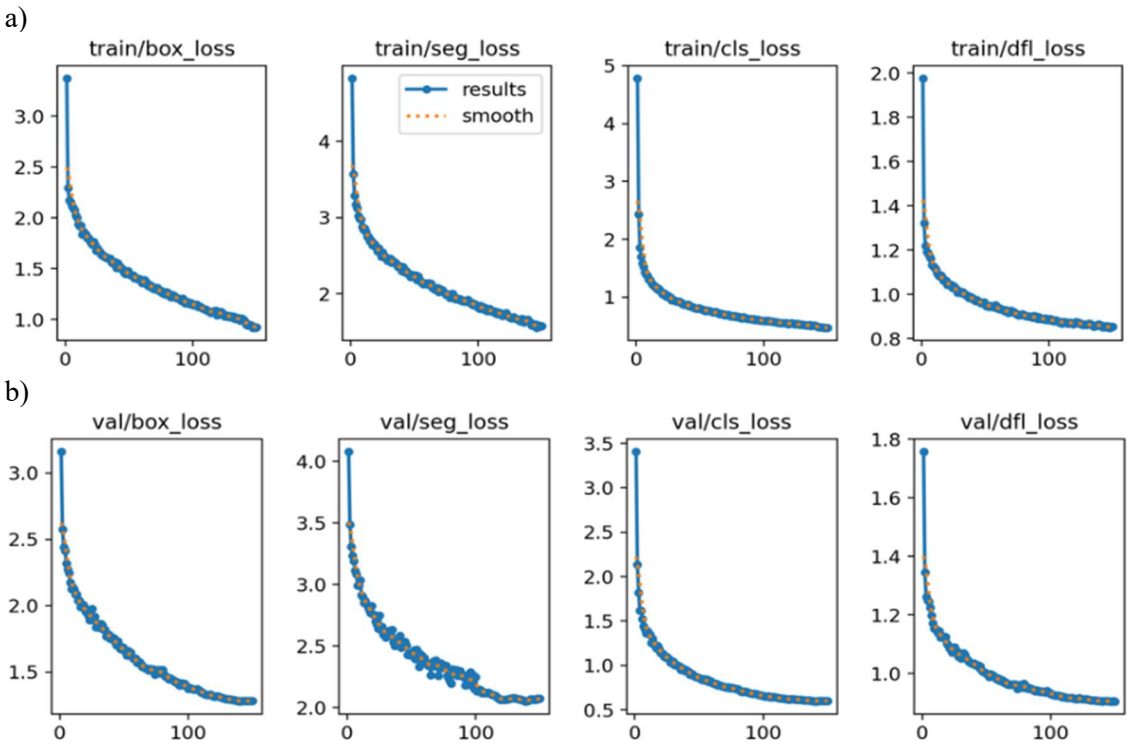
a)

b)



Rys. 79. Proces uczenia modelu YOLOv12-x – wartość straty modelu

Analiza przebiegu uczenia wskazuje, że w kolejnych iteracjach wartości funkcji strat dla wszystkich monitorowanych metryk ulegają systematycznej redukcji zarówno w zbiorze treningowym, jak i walidacyjnym. Taki trend świadczy o zdolności modelu do generalizacji cech, co jest kluczowe dla poprawnej klasyfikacji wykrywanych wad. Na poniższych rysunkach przedstawiono przebieg wartości metryk ewaluacyjnych: precyzji, czułości, mAP50 oraz mAP50–90, w kolejnych epokach dla zadania detekcji obiektów (Box) (Rys. 80a) oraz segmentacji (Mask) (Rys. 80b).



Rys. 80. Proces uczenia modelu YOLOv12-x – wartości metryk

Eksperymenty przeprowadzono na stacji roboczej wyposażonej w kartę graficzną NVIDIA GeForce RTX 5090 z 32 GB pamięci VRAM. Uzyskane rezultaty oraz czasy inferencji poszczególnych modeli zostały przedstawione w tabeli 25.

Tabela 25. Ewaluacja modeli YOLOv12 w zadaniu segmentacji wad

Rozmiar Modelu	mAP50 (Mask)	mAP50-95 (Mask)	mAP50 (Box)	mAP50-95 (Box)	Czas inferencji [ms]
n - Nano	0,43	0,16	0,491	0,235	0,2
s - Small	0,54	0,21	0,633	0,337	0,2
m - Medium	0,61	0,26	0,706	0,409	0,4
l - Large	0,60	0,25	0,704	0,413	0,6
x - Extra Large	0,64	0,28	0,749	0,462	0,8

Uzyskane wyniki jednoznacznie potwierdzają wysoką skuteczność modeli YOLOv12-Seg w zadaniach detekcji oraz segmentacji defektów powstających po procesie zgrzewania opakowań. Wraz ze wzrostem złożoności architektury obserwuje się systematyczną poprawę jakości predykcji, co wskazuje na lepszą reprezentację cech i większą zdolność modelu do uogólniania. Wariant extra-large osiąga najwyższe wartości metryk, uzyskując mAP50(box) na poziomie 75%. Czasy inferencji na poziomie 0,2–0,8 ms dla pojedynczego fragmentu obrazu są natomiast wystarczająco niskie, aby spełnić rygorystyczne wymagania przemysłowych systemów kontroli jakości. Nawet w przypadku konieczności przetwarzania kilkudziesięciu

fragmentów obrazów o wysokiej rozdzielczości, łączny czas analizy pozostaje zgodny z założeniami projektowymi systemu inspekcyjnego.

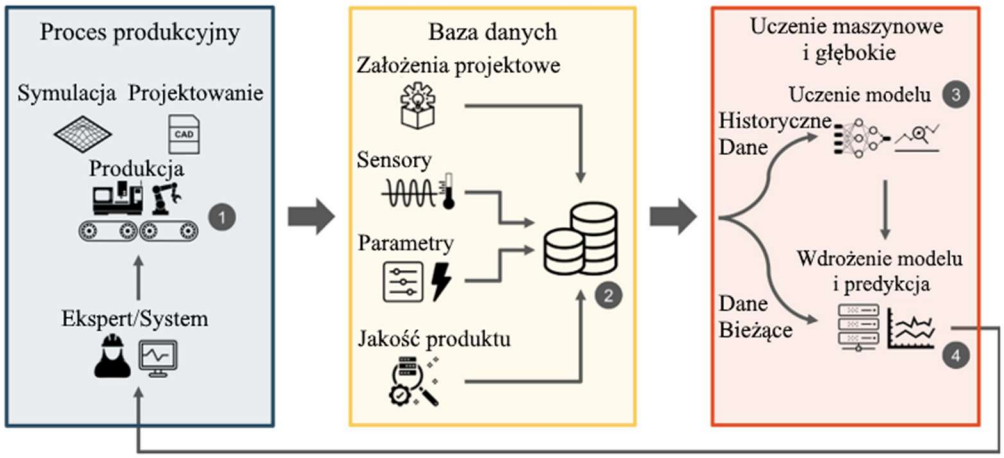
Podsumowanie

Wykonane badania eksploracyjne miały na celu ocenę możliwości zastosowania fuzji obrazów i metod sztucznej inteligencji do klasyfikacji defektów powstających w wyniku procesu zgrzewania termicznego opakowań. Przygotowany zbiór danych charakteryzował się znacznym poziomem trudności podczas etykietowania i analizy ze względu na naturalnie niski kontrast, subtelny charakter cech defektów oraz wysokie podobieństwo wizualne pomiędzy obszarami różnych klas. Dodatkowo, analizowane dane znacząco odbiegały od naturalnych zbiorów obrazów powszechnie wykorzystywanych do trenowania modeli głębokiego uczenia. Biorąc pod uwagę ograniczoną liczbę danych, uzyskane wyniki umożliwiły jednoznaczne potwierdzenie obecności stabilnych, możliwych do wyuczenia wzorców. Należy jednak podkreślić, że na wczesnym etapie prac kluczową rolę odgrywają metody augmentacji obrazów, bez których jakość wyników uzyskiwanych przez trenowane modele była istotnie niższa. Odpowiednio dobrane techniki augmentacyjne stanowią zatem niezbędny element procesu przygotowania danych, wpływając bezpośrednio na stabilność i ogólną skuteczność modeli.

Pomimo, że osiągnięty poziom skuteczności opracowanych modeli nie spełnia wymagań dla przemysłowych systemów inspekcji, stanowi istotny rezultat i punkt odniesienia w dalszych pracach. Wyniki przeprowadzonych badań, analizujące zależność pomiędzy skalą architektury modelu a efektywnością klasyfikacji, wskazują, że uzyskanie kilkuprocentowej poprawy wartości metryk ewaluacyjnych może wiązać się z nawet dwukrotnym wydłużeniem czasu inferencji. Z tego względu dobór architektury sieci powinien być każdorazowo dokonywany w sposób świadomy i adekwatny do specyfiki danego zadania inspekcyjnego, tak aby zapewnić optymalny kompromis pomiędzy jakością predykcji, a wydajnością obliczeniową.

Badania eksperymentalne

Fundamentem nowoczesnego zarządzania produkcją staje się pełna integracja czujników i systemów inspekcyjnych z liniami technologicznymi. Dzięki temu przedsiębiorstwa mogą na bieżąco gromadzić i analizować dane na każdym etapie wytwarzania. Wykorzystanie metod uczenia maszynowego i fuzji obrazów pozwala na identyfikację trendów, wykrywanie anomalii oraz minimalizację zużycia zasobów. Bieżące monitorowanie pracy maszyn i wyników kontroli pomaga określić zależności między zmiennością procesu, a końcową jakością wyrobów. W kontekście pakowania produktów jednym z kluczowych kryteriów jakościowych jest wytrzymałość połączenia zgrzewanego, a sam obszar łączenia materiału stanowi najbardziej newralgiczny element. Z tego względu powinien być on poddawany wyjątkowo dokładnej kontroli. Standardowe metody wizyjne nie pozwalają na bezpośrednią ocenę cech fizycznych i mechanicznych opakowań takich jak wytrzymałość połączenia zgrzewanego oraz szczelności opakowania [195]. W tym celu stosuje się specjalistyczne urządzenia, które pozwalają na statystyczną weryfikację zgodności uzyskanych parametrów z wymaganiami technicznymi. Są to w przeważającej mierze techniki niszczące, realizowane w laboratoriach kontroli jakości lub na stanowiskach zlokalizowanych bezpośrednio przy stanowisku produkcyjnym. W praktyce przemysłowej powszechnie wykorzystywanym rozwiązaniem w tym zakresie jest test rozerwania (*ang. burst test*) polegający na doprowadzeniu do perforacji opakowania w wyniku działania sprężonego powietrza wtłaczanego do jego wnętrza. Proces kontroli połączenia zgrzewanego wykonywany jest w określonych odstępach czasu, odpowiadających ustalonej ilości wyprodukowanych opakowań. Metody statystycznej kontroli procesu są obecnie powszechnie wykorzystywane w wielu procesach produkcyjnych. Zgodnie z założeniami Przemysłu 4.0 tradycyjną kontrolę wyrywkową zastępuje się zautomatyzowanymi systemami kontroli jakości oraz sensorami zgodnymi z koncepcją Internetu Rzeczy oraz rozwiązaniami opartymi na sztucznej inteligencji. Dzięki temu możliwe jest ciągłe monitorowanie procesów, szybka identyfikacja odchyleń od założonych parametrów oraz podejmowanie działań korygujących w czasie rzeczywistym (Rys. 81).



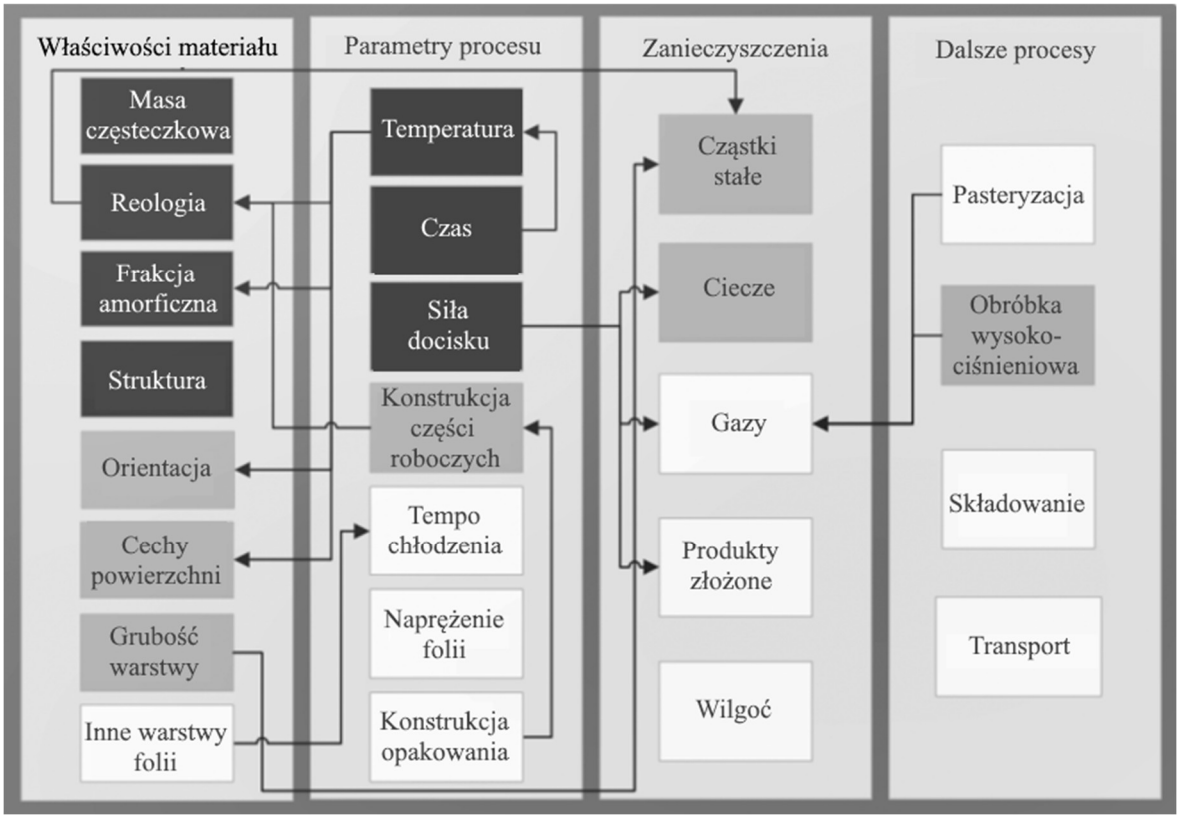
Rys. 81. Metoda predykcji jakości w procesach wytwarzania [196]

Metodyka predykcyjnej jakości obejmuje cztery zasadnicze etapy [196]:

- określenie procesu wytwarzania oraz docelowych parametrów jakości,
- wybór oraz gromadzenie danych procesowych i jakościowych,
- trenowanie modelu uczenia maszynowego lub głębokiego uczenia,
- wykorzystanie modelu do estymacji jako podstawy podejmowania decyzji.

W takim podejściu predykcja jakości polega na estymacji jakości jako wartości numerycznej, za pomocą modelu na podstawie zmiennych procesowych i jakościowych. Celem jest przewidywanie jakości produktu zarówno dla wspomagania decyzji, jak i automatyzacji procesów. W ramach przeprowadzonych badań zrealizowano serię eksperymentów, których celem było określenie możliwości wyznaczenia zależności pomiędzy parametrami procesu zgrzewania, wynikami inspekcji przeprowadzanej z wykorzystaniem opracowanego systemu hybrydowego oraz wynikami badań niszczących określających siłę połączenia zgrzewanego opakowania [197].

Podczas procesu zgrzewania termicznego na wytrzymałość oraz integralność zgrzeiny wpływ ma wiele czynników. Można je podzielić na cztery główne kategorie [145]: parametry procesu, właściwości materiału, zanieczyszczenia oraz dalsze etapy obróbki (Rys. 82).



Rys. 82. Czynniki wpływające na jakość połączenia zgrzewanego opakowania [145]

Jakość połączenia zgrzewanego jest silnie uzależniona od podstawowych parametrów procesu, takich jak temperatura, czas i ciśnienie. Wykorzystując zależności pomiędzy tymi parametrami oraz ich precyzyjną kontrolę, możliwe jest uzyskanie różnych typów połączeń

zgrzewanych: trwałych (*ang. lock seal*) lub łatwo otwieralnych (*ang. peel seal*), a także obniżenie zużycia energii lub osiągnięcie wysokich prędkości procesu. Niewłaściwe ustawienie tych parametrów może jednak prowadzić do licznych problemów, które w konsekwencji skutkują niską jakością połączenia zgrzewanego oraz powstawaniem nieszczelności.

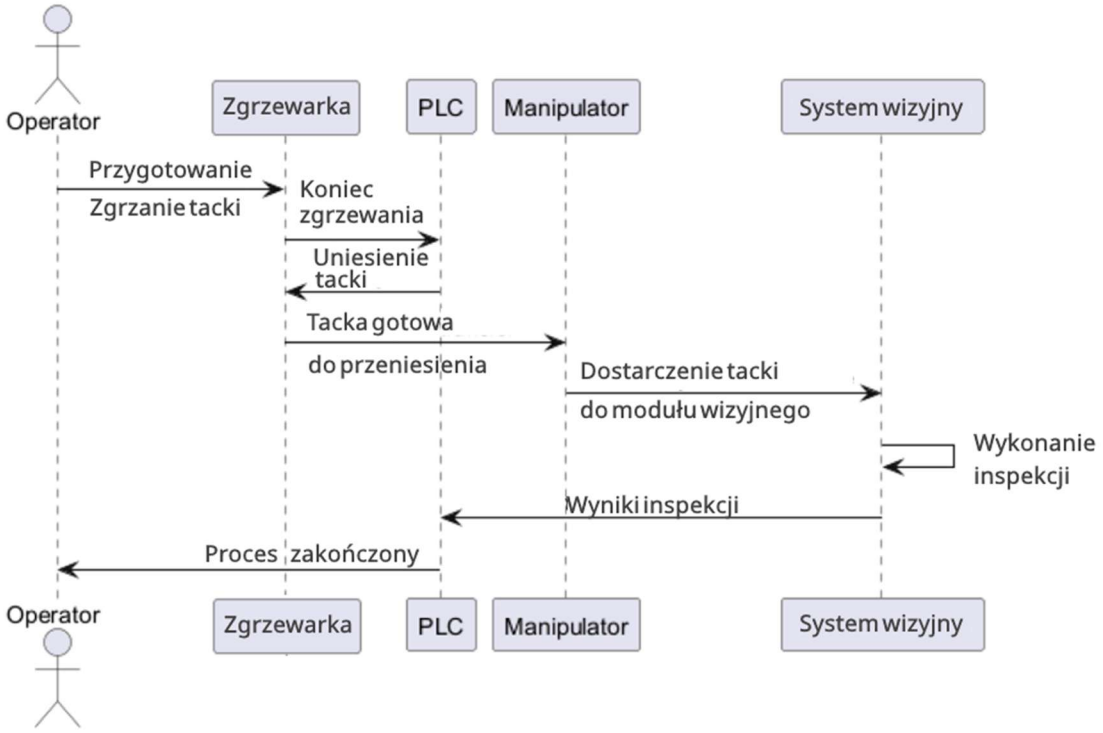
4.7. Zrobotyzowane stanowisko badawcze

Do przeprowadzenia badań wykorzystano stanowisko laboratoryjne wyposażone w opracowany systemem inspekcji, który zintegrowany został z manipulatorem przemysłowym (Rys. 83).



Rys. 83. System inspekcji zintegrowany z manipulatorem przemysłowym

Integracja programowo-sprzętowa oraz mechaniczna zapewniły powtarzalność i precyzję w procesie manipulacji tackami. Każdy moduł realizował czasowo zdefiniowaną funkcję w procesie nadzorowanym przez sterownik PLC. Rozwiązanie to umożliwiło zasymulowanie procesu zgrzewania zgodnie z cyklem operacyjnym, który przedstawiony został na schemacie (Rys. 84).



Rys. 84. Przebieg procesu akwizycji danych

Przed rozpoczęciem procesu akwizycji danych, tacka umieszczana jest w gnieździe roboczym zgrzewarki i nakładana jest na nią folia. Kolejnym etapem jest zamknięcie górnej pokrywy urządzenia. W przedniej części obudowy zgrzewarki zamontowany jest czujnik położenia, którego sygnał wejściowy pełni funkcję warunku inicjującego procedurę odmierzania czasu zgrzewania. Po aktywacji czujnika sterownik PLC przechodzi do stanu pomiarowego, realizując proces zgodnie z parametrem czasowym zdefiniowanym w konfiguracji urządzenia. Po upływie zadanego czasu sterownik PLC aktywuje sygnalizator świetlny, generując komunikat o zakończeniu fazy zgrzewania. W odpowiedzi na sygnał operator otwiera pokrywę urządzenia, inicjując rejestrację termogramu płyty grzewczej za pomocą dodatkowej kamery termowizyjnej. Następnie rozpoczyna się w pełni zautomatyzowana sekwencja procesu. Siłownik zintegrowany z modułem zgrzewarki unosi tackę, która jest przekładana przez manipulator na stanowisko wizyjne. Tam tacka zostaje osadzona w dedykowanym gnieździe. Napęd liniowy przemieszcza tackę pod systemem wizyjnym z zadaną prędkością. Poprzez automatyzację procesu zbierania danych, obrazy rejestrowane były w założonym czasie po zakończeniu procesu zgrzewania, zapewniając w ten sposób warunki zbliżone do rzeczywistych. Każda wykonana próba, poza rejestrowanymi obrazami, została opisana za pomocą pliku z metadanymi o procesie zgrzewania. Struktura danych rejestrowanych w bazie została przedstawiona w tabeli 26. Wszystkie wymagane czasy w analizowanych procesie są mierzone w module PLC z rozdzielczością wynoszącą 1 ms.

Tabela 26. Struktura metadanych procesu akwizycji

Parametr	Wartość
Czas akwizycji t_a	8670 [ms]
Czas zgrzewania t_z	1909 [ms]
Ustawiona temperatura zgrzewania	190 [°C]
Czas ekspozycji linii kamery VIS	100 [µs]
Częstotliwość skanowania kamery VIS	2560 [Hz]

Szczegółowe wyniki dotyczące procesu akwizycji danych przedstawione zostały w tabeli 27. Wyznaczone odchylenie standardowe czasu wyzwolenia pierwszej kamery wyniosło σ=17 ms, dla grupy 118 próbek. Rozrzut czasu zgrzewania wyniósł 1,3 s, z medianą zbliżoną do wartości nominalnej wynoszącej 2 sekundy.

Tabela 27. Dane statystyczne wykonanych badań laboratoryjnych

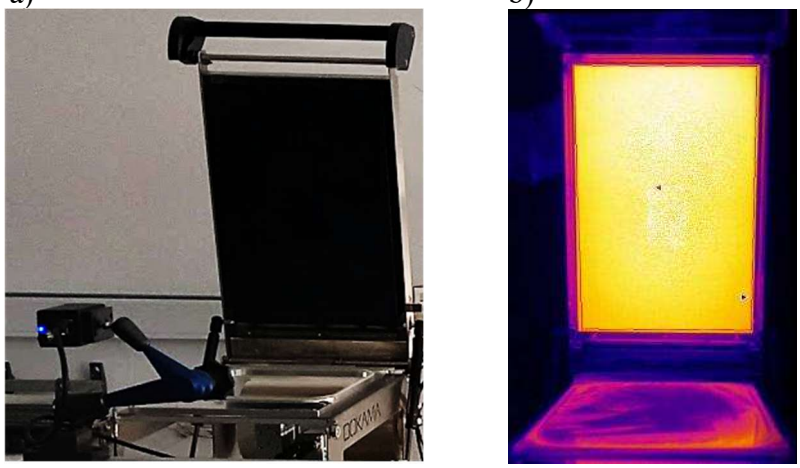
Parametr	Czas [ms]
Średni czas akwizycji t_a	8661
Odchylenie standardowe t_a	17
Mediana t_a	8669
Wartość minimalna t_a	8617
Wartość maksymalna t_a	8678
Średni czas zgrzewania t_z	2121
Odchylenie standardowe t_z	305
Mediana t_z	2020
Wartość minimalna t_z	1852
Wartość maksymalna t_z	3152

Na podstawie zarejestrowanych wyników pomiarów, próbki zostały skategoryzowane pod względem czasu zgrzewania:

- czas poniżej 1950 ms (23 próbki),
- prawidłowy czas zgrzewania od 1950 ms do 2050 ms (51 próbek),
- czas powyżej 2050 ms (44 próbki).

Drugim z analizowanych parametrów procesu była temperatura zgrzewania, stanowiąca kluczowy czynnik wpływający na jakość połączenia zgrzewanego. Ze względu na nieprecyzyjny układ regulacji temperatury w zastosowanej zgrzewarce, podczas badań poza nastawami rejestrowany był również rozkład temperatury płyty grzewczej. W tym celu wykorzystana została kamera termowizyjna firmy FLIR model A35 (Rys. 85a), dedykowana do ciągłego monitorowania procesów przemysłowych. Na zarejestrowanych termogramach odnotowano wyraźną niejednorodność rozkładu temperatury, przejawiającą się systematycznie podwyższonymi wartościami w górnej części analizowanego obszaru (Rys. 85b).

a) b)



Rys. 85. Pomiary temperatury płyty grzewczej a) kamera FLIR A35 b) przykładowy termogram

Podstawowe parametry zastosowanej kamery termowizyjnej przedstawione zostały w tabeli 28.

Tabela 28. Parametry kamery Flir A35

Typ sensora	Mikrobolometryczny
Zakres spektralny	7,5 - 13 µm
Zakres pomiarowy	–40 to +550 °C
Czułość termiczna	50 mK
Dokładność pomiaru	±5 °C lub ±5 % odczytu
Rozmiar piksela	17 µm
Rozdzielczość sensora	320 x 256 px
Częstotliwość akwizycji	60 Hz

W każdym z wykonanych testów, w wyznaczonym obszarze ROI płyty grzewczej wykonana została analiza rozkładu temperatury. Na rysunku powyżej oznaczone są, odpowiednio znacznikami czerwonym i niebieskim, wartości maksymalne oraz minimalne. Podczas testów dla każdej próby wygenerowany został plik z wynikami pomiarów termowizyjnych (Tab. 29).

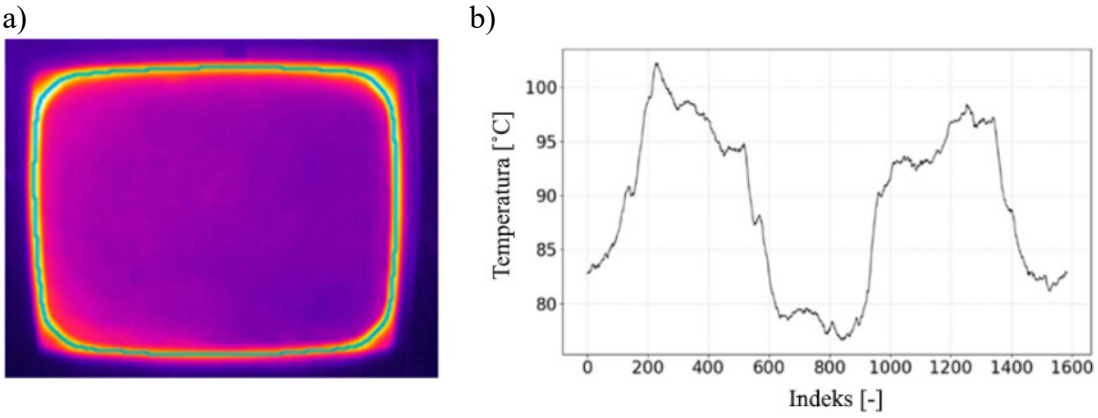
Tabela 29. Przykładowe dane pomiarowe termogramy płyty grzewczej

Parametr	Wartość
Temperatura średnia	161,5 [°C]
Odchylenie standardowe temperatury	5,6 [°C]
Temperatura maksymalna	172,7 [°C]
Temperatura minimalna	140,6 [°C]
Liczba pikseli	73724
Emisyjność	0,95
Dystans	1 [m]

Współczynnik emisyjności płyty grzewczej określono z wykorzystaniem specjalistycznej taśmy wysokotemperaturowej o znanej wartości tego parametru, stanowiącej materiał referencyjny podczas kalibracji pomiarów termowizyjnych [198]. Po ustawieniu wartości emisyjności taśmy w oprogramowaniu, uzyskano temperaturę jej powierzchni. Szukaną emisyjność powierzchni wyznaczono, zmieniając wartość tego parametru w oprogramowaniu, aż do momentu, gdy temperatura powierzchni płyty grzewczej zrównała się ze znaną temperaturą powierzchni taśmy.

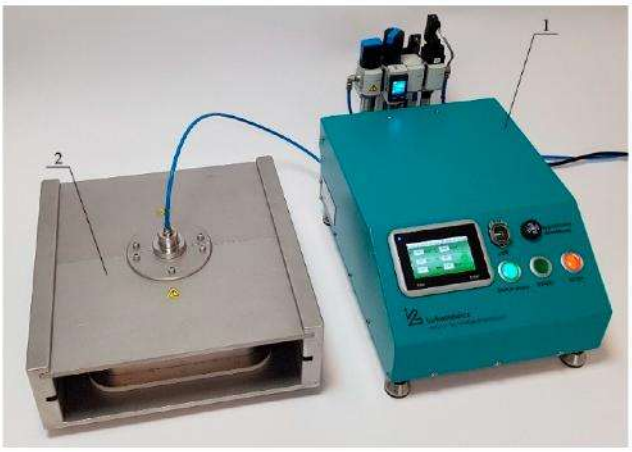
Poza danymi związanymi z procesem zgrzewania termicznego do utworzonego zbioru danych dołączone zostały dane dotyczące jakości opakowań. Rezultaty inspekcji określone zostały na podstawie analizy zarejestrowanych obrazów po operacji fuzji. Dla każdej próbki zapisywane były zidentyfikowane wady w postaci zagniecenia przy niskiej temperaturze (*ang. Crease LT low temperature*), zagniecenia przy wysokiej temperaturze (*ang. Crease HT high temperature*) słabe połączenia zgrzewane (*ang. Weak Bond*), zanieczyszczenia (*ang. Contaminant*) i zmarszczki (*ang. Wrinkles*). Za wady danej klasy uznano obszary o rozmiarze przekraczającym 50 px, co odpowiada powierzchni większej niż 1 mm². Ponadto, uwzględniony został także łączny wynik oceny jakości połączenia zgrzewanego (*ang. Total Score*).

Dodatkowo, za pomocą opracowanego algorytmu dla każdego opakowania analizowany był profil temperatury obszaru zgrzewania (Rys. 86a). Ze względu na zastosowanie zgrzewarki ręcznej, na zarejestrowanych profilach (Rys. 86b) widoczne są znaczne, okresowe wahania temperatury, wynikające z nierównomiernego docisku oraz niejednorodnego rozkładu temperatury na płycie grzewczej.



Rys. 86. Analiza temperatury w obszarze zgrzewu a) termogram b) profil temperaturowy

Testy opakowań mające na celu wyznaczenie siły połączenia zgrzewanego wykonano za pomocą urządzenia, którego producentem jest Ł-ITeE (Rys. 87). Urządzenie przeznaczone jest do kontroli jakości off-line. Proces kontroli zgrzeiny wykonywany jest metodą niszczącą polegającą na wprowadzaniu za pomocą sondy do wnętrza pojemnika sprężonego powietrza i pomiarze ciśnienia (wyrażonego w kG/cm^2) przy którym następuje rozerwanie zgrzewu.



Rys. 87. Tester opakowań: 1 - moduł sterująco - pomiarowy, 2 - moduł wykonawczy [197]

Przygotowaną do testu tackę z zamontowaną sondą umieszcza się między górną a dolną płytą modułu wykonawczego. Podczas testu mierzone są zmiany ciśnienia wewnątrz opakowania, aby określić maksymalną wartość, przy której nastąpi pęknięcie uszczelnienia. Wynik pomiaru uznaje się za poprawny, jeśli zmierzona maksymalna wartość ciśnienia wewnątrz zgrzewanego opakowania jest większa lub równa od ustalonej wartości granicznej.

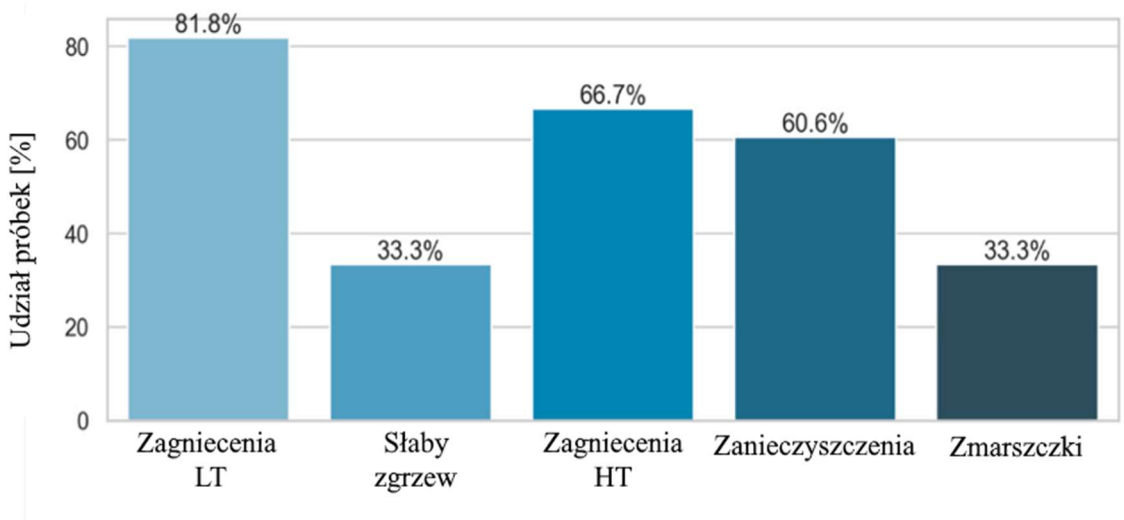
4.8. Analiza danych z wykorzystaniem metod uczenia maszynowego

Ze względu na szereg czynników zakłócających, w tym nieprawidłowości podczas przygotowania próbek, uzyskanie wiarygodnego rezultatu badania niszczącego było w niektórych próbach niemożliwe. W przypadku nieszczelności opakowania lub nieszczelnością połączenia sondy z opakowaniem, wzrost ciśnienia jest wolniejszy od referencyjnej charakterystyki (Rys. 88). W takich przypadkach pomiar zostaje przerwany po upływie ustawionego czasu bez podania rezultatu



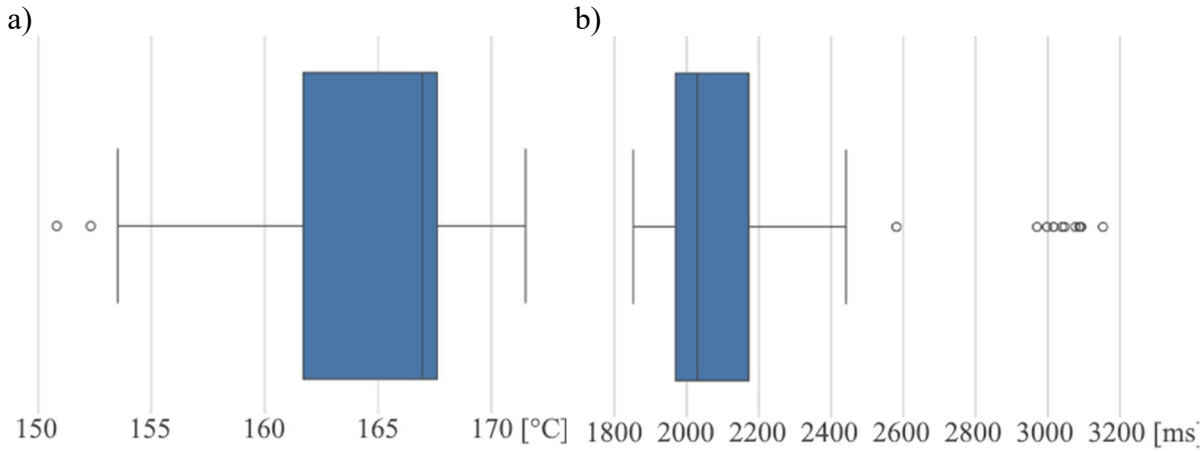
Rys. 88. Wykres pomiaru ciśnienia [197]

W wyniku przeprowadzonego procesu oczyszczania zarejestrowanych danych, z dalszej analizy wykluczono te próbki, dla których tester ciśnieniowy zgłosił błąd pomiaru. W konsekwencji, ostateczny zbiór danych stanowiło 66 reprezentatywnych próbek. Strukturę oraz rozkład procentowy defektów, zidentyfikowanych za pomocą opracowanego systemu hybrydowej inspekcji, zilustrowano szczegółowo na rysunku 89. W wielu przypadkach na zarejestrowanych obrazach stwierdzano jednoczesne występowanie kilku wad. Przeprowadzona analiza wykazała, że dominującą grupę stanowiły zagniecenia folii w obszarze zgrzewania. Powstawanie tego typu uszkodzeń spowodowane było zazwyczaj przez niedostateczne naprężenie materiału lub jego niewłaściwe pozycjonowanie.



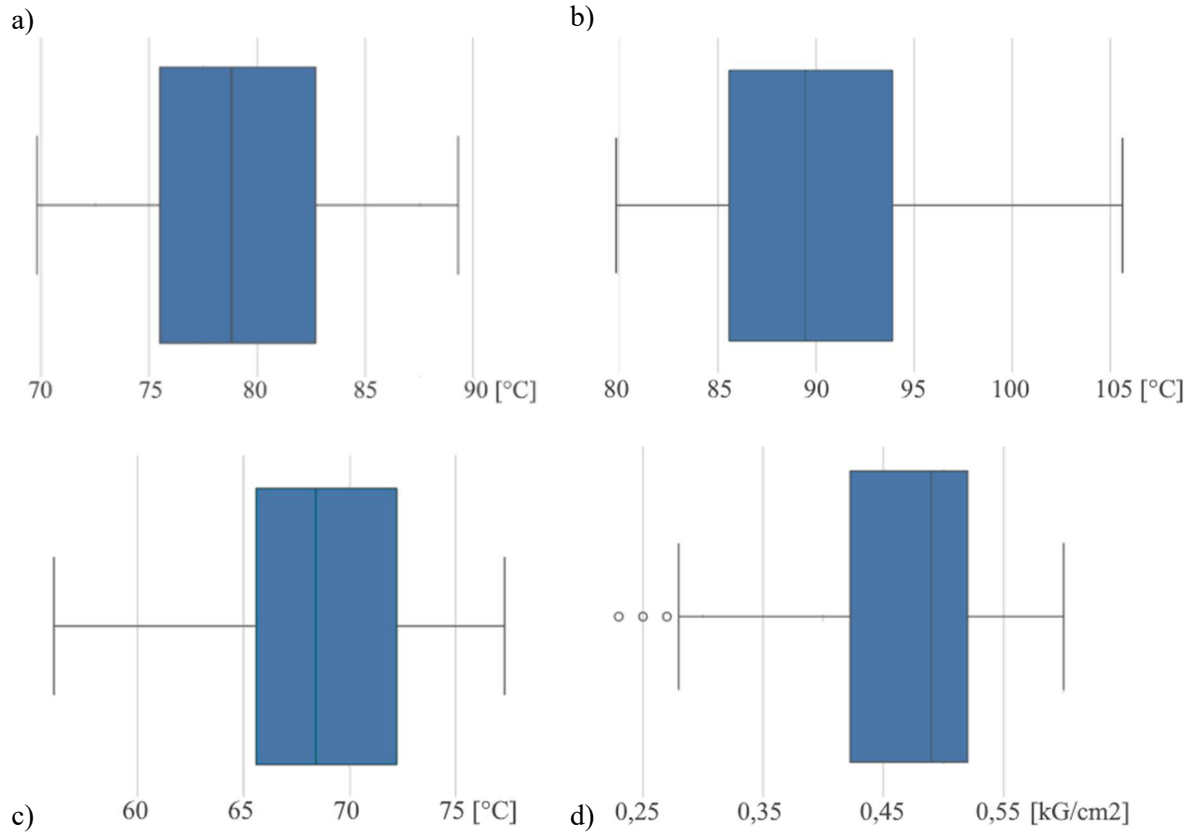
Rys. 89. Procentowy udział defektów wykrytych w analizowanych próbkach

Rozkład zarejestrowanych parametrów procesowych obejmujących zmierzoną temperaturę płyty grzewczej - mTemp (Rys. 90a) oraz czas zgrzewania - hTime (Rys. 90b), przedstawiono za pomocą wykresów pudełkowych (*ang. box plot*).



Rys. 90. Rozkład danych analizowanych parametrów procesu a) temperatura płyty b) czas zgrzewania

Ciemnoniebieskie prostokąty odpowiadają zakresowi od pierwszego do trzeciego kwartyla (Q1–Q3), natomiast pionowa linia wewnątrz prostokąta wyznacza wartość mediany. Punkty oznaczone symbolami kół reprezentują wartości sklasyfikowane jako odstające zgodnie z kryterium rozstępu ćwiartkowego IQR (*ang. Interquartile range*). Metoda ta umożliwia jednoznaczną identyfikację obserwacji wykraczających poza typowy zakres zmienności analizowanych parametrów procesowych [199]. „Wąsy" przedstawiają zakres danych po wykluczeniu obserwacji uznanych za odstające. Do wyznaczenia ich wartości przyjęta została wartość 1.5 × IQR. Na wykresach przedstawionych poniżej (Rys. 91 a, b, c) zaprezentowano rozkład zmierzonej temperatury próbek (średniej - tempAVG, maksymalnej - tempMax i minimalnej - tempMin) zarejestrowanej za pomocą opracowanego systemu inspekcji.

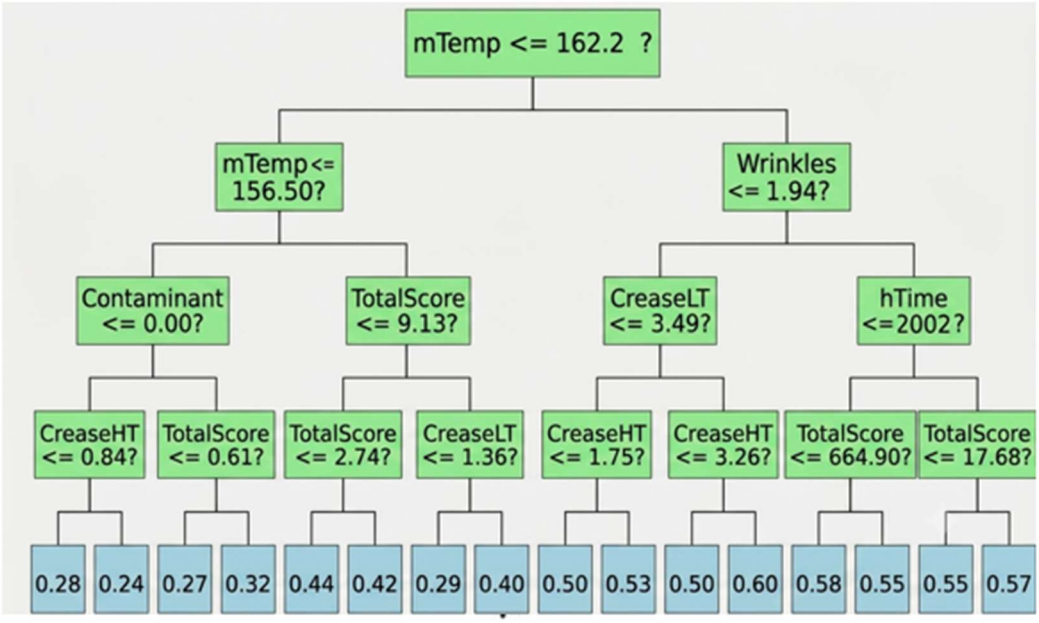


Rys. 91. Rozkład danych analizowanych parametrów a) temperatura zgrzewu: średnia b) maksymalna c) minimalna d) rezultat testu ciśnieniowego

Na wykresie rezultatu testu ciśnieniowego (Rys. 90d) można zaobserwować, że ponad połowa próbek osiągnęła wynik przekraczający założony próg (0,45 kG/cm^2). Ponadto, zmienność wyników testu ciśnieniowego wykazuje rozkład zbliżony do średniej temperatury płyty grzewczej, co potwierdza bezpośrednią zależność pomiędzy tymi parametrami.

W celu opracowania modelu predykcyjnego procesu zastosowano podejście wieloetapowe, obejmujące selekcję cech, dostrajanie hiperparametrów oraz porównanie różnych modeli regresji. W pierwszej kolejności wykonano procedurę identyfikacji i selekcji predyktorów,

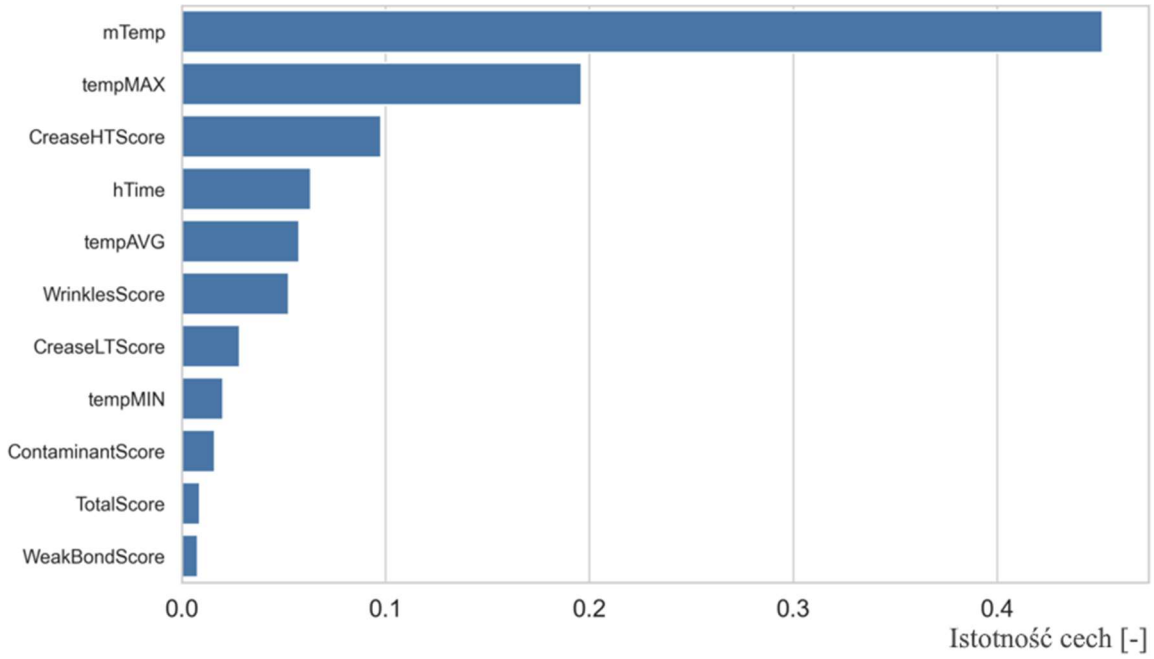
których wartości mają największy wpływ na zmienną objaśnianą. Celem tej analizy było określenie zależności pomiędzy parametrami procesu oraz danymi o sklasyfikowanych wadach na uzyskiwane wyniki testów ciśnieniowych. W tym celu zastosowana została metoda RFE (*ang. Recursive Feature Elimination*) z estymatorem bazowym Random Forest Regressor [200]. W zastosowanej procedurze proces uczenia modeli rozpoczyna się od losowego podziału danych na podzbiory treningowe i testowe, z zastosowaniem współczynnika podziału 80/20. Na rysunku 92 przedstawione zostało przykładowe pojedyncze drzewo decyzyjne wygenerowane na podstawie danych z opracowanego zbioru.



Rys. 92.Przykład predykcji jakości zgrzewu z wykorzystaniem metody drzew decyzyjnych

Jak można zaobserwować, w analizowanym przypadku za zmienną kluczową dla podziału danych, uznano zmierzoną temperaturę płyty zgrzewającej. W wyodrębnionym podzbiorze, przy wskazaniach nieprzekraczających 162,2 °C, niezależnie od poziomu pozostałych parametrów wynik testu ciśnieniowy wyniósł mniej niż 0,45 kG/cm^2, czyli poniżej przyjętego progu.

Metoda RFE polega na iteracyjnym eliminowaniu najmniej istotnych cech, co pozwala na wybranie podzbioru zmiennych, które mają największe znaczenie dla przewidywania wartości docelowej. Na rysunku 93 przedstawione zostały uzyskane wyniki analizy istotności zmiennych.



Rys. 93. Wyznaczenie wpływu predyktorów na zmienną objaśnianą za pomocą metody RFE

Po zdefiniowaniu istotności poszczególnych zmiennych, kolejnym niezbędnym krokiem w procedurze estymacji modelu jest wyznaczenie liczby cech uwzględnianych podczas jego trenowania. Nadmierna liczba zastosowanych cech może prowadzić do przeuczenia modelu (*ang. overfitting*) i jego zbyt dużego dopasowania do zbioru treningowego. Z kolei zbyt mała liczba estymatorów może uniemożliwić osiągnięcie wymaganej dokładności predykcji. Jednym z kryteriów stosowanych do wyznaczenia optymalnej liczby predyktorów jest reguła OPV (*ang. Observations Per Variable*). W literaturze przyjmuje się, że dopasowany model regresji będzie prawdopodobnie wiarygodny, gdy liczba predyktorów p jest mniejsza niż $m/10$ lub $m/20$, gdzie m oznacza liczbę próbek. Jako wartość bazową przyjmuje się średnią warunek $p < m/15$ [201]. W omawianym przypadku, dla 66 próbek maksymalna liczba wykorzystanych predyktorów powinna wynosić maksymalnie 4. Na tej podstawie do modelowania wybrano jako zmienne objaśniające:

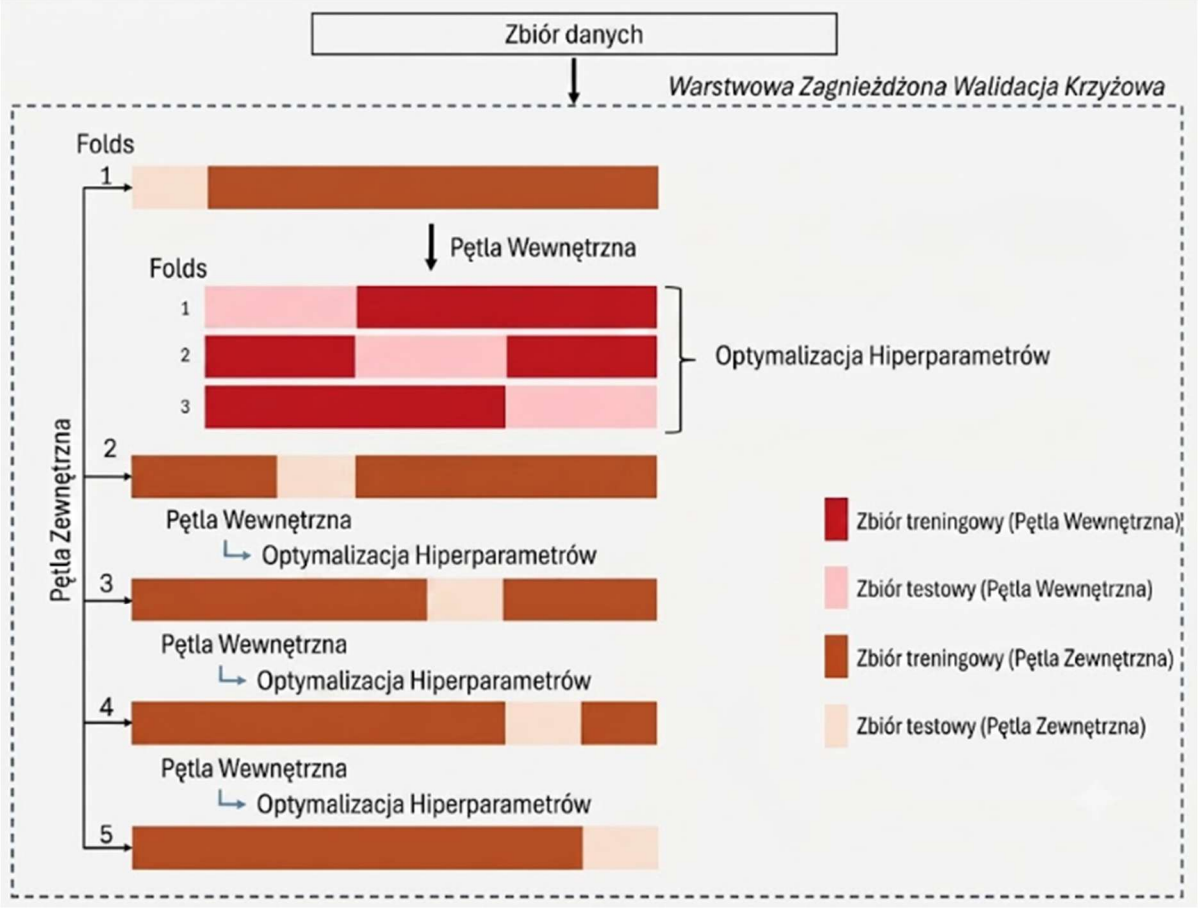
- temperaturę płyty grzewczej,
- maksymalną zmierzoną temperaturę w obszarze zgrzewania,
- wady w postaci zagniecenia przy wysokiej temperatury,
- czas zgrzewania.

Ze względu na niewielką ilość dostępnych danych treningowych w zbiorze, do modelowania zastosowano zestaw klasycznych metod regresji obejmujący:

- Ridge Regression — liniowy model z regularyzacją L2, przeciwdziałający przeuczeniu,
- Lasso Regression — regresja z regularyzacją L1, sprzyjająca eliminacji nieistotnych predyktorów,
- Elastic Net — kombinacja regularyzacji L1 i L2, łącząca zalety metod Ridge i Lasso

- Support Vector Regression (SVR) — model regresji wykorzystujący funkcje jądrowe (*ang. kernel methods*), umożliwiający modelowanie zarówno zależności liniowych, jak i nieliniowych oraz cechujący się dobrą zdolnością do generalizacji,
- Random Forest Regressor — model zespołowy oparty na agregacji wielu drzew decyzyjnych (*ang. bagging*), odporny na przeuczenie i dobrze radzący sobie z dużą liczbą cech, umożliwiający jednocześnie ocenę ich istotności.

Modele te są powszechnie stosowane w podobnych badaniach ze względu na ich stabilność i interpretowalność [202]. W zastosowanej procedurze, dla każdego modelu hiperparametry są dostrajane w ramach zagnieżdżonej struktury walidacji krzyżowej [203]. Pętla wewnętrzna wykorzystuje trzykrotną walidację krzyżową w celu wyznaczenia optymalnych hiperparametrów. Skuteczność generalizacji dostrojonych modeli jest następnie szacowana w pętli zewnętrznej przy użyciu pięciokrotnej walidacji krzyżowej 5-Fold, co zapewnia obiektywną ocenę modelu. Opisana procedura została przedstawiona na rysunku 94.



Rys. 94. Schemat zagnieżdżonej walidacji krzyżowej 5 × 3 [204]

W tabeli 30 zestawiono rezultaty pięciu modeli regresyjnych w zakresie prognozowania wartości testu ciśnieniowego. Jakość predykcji oceniono za pomocą następujących metryk: średniego błędu bezwzględnego (MAE), pierwiastka błędu średniokwadratowego (RMSE) oraz

współczynnika determinacji R^2. Najwyższą skuteczność osiągnął model ElasticNet, który uzyskał najniższy średni błąd bezwzględny ($MAE = 0{,}028$ kG/cm^2) oraz najwyższy współczynnik determinacji ($R^2 = 0{,}815$). Otrzymane wyniki wskazują, że model ten wśród porównywanych metod najdokładniej odwzorowywał zależność między zmiennymi, a rezultatem testu ciśnieniowego.

Tabela 30. Porównanie skuteczności modeli predykcji jakości zgrzewu

Model	MAE [kG/cm²]	RMSE [kG/cm²]	R^2 [-]
ElasticNet	0,028	0,037	0,815
Ridge	0,029	0,037	0,814
Lasso	0,029	0,038	0,809
SVR	0,029	0,038	0,805
RandomForest	0,039	0,048	0.686

Ocena dokładności predykcji wytrzymałości połączenia zgrzewanego z wykorzystaniem pięciokrotnej walidacji krzyżowej ogranicza ryzyko uzyskania zbyt optymistycznej lub zbyt pesymistycznej oceny skuteczności modelu, które mogłoby wystąpić przy pojedynczym losowym podziale danych na zbiory treningowy i testowy. W celu oceny stabilności modelu ElasticNet oraz zmienności uzyskiwanych wyników dla całego zbioru danych zastosowano dodatkowo procedurę bootstrap z wielokrotnym próbkowaniem [205]. Zgodnie z tą procedurą dla każdej iteracji bootstrapu wykonana została następująca sekwencja [206]:

- z oryginalnego zbioru danych losuje się pojedynczy przypadek i przypisuje się go do danej próby bootstrapowej. Krok ten jest powtarzany do momentu, gdy wielkość tworzonej próby osiągnie rozmiar taki jak pierwotny zbiór danych,
- do każdej z uzyskanych prób bootstrapowych dopasowuje się model,
- następnie oblicza się jego dokładność na zbiorze treningowym.
- proces kończy agregacja wyników, polegająca na wyznaczeniu ostatecznej dokładności modelu jako średniej arytmetycznej z uzyskanych wcześniej prób.

Ponieważ losowanie odbywa się ze zwracaniem, pewne obserwacje mogą pojawić się w danej próbie wielokrotnie, inne zaś mogą nie zostać wylosowane wcale (Rys. 95).



Rys. 95. Procedura bootstrapu z powtórzeniami [206]

Procedura ta może być stosowana przy niewielkich zbiorach danych i umożliwiła oszacowanie zmienności metryk wydajności modelu i odpowiadających im przedziałów ufności. Ponieważ każda próbka bootstrapowa jest tworzona poprzez losowanie obserwacji ze zwracaniem, poszczególne zbiory treningowe różnią się swoim składem. W konsekwencji model w kolejnych iteracjach może być trenowany z większym udziałem określonych przypadków, podczas gdy inne obserwacje mogą występować rzadziej. Uśrednienie wyników uzyskanych dla dużej liczby takich prób pozwala ograniczyć wpływ pojedynczego losowania danych na ocenę jakości modelu oraz zapewnia bardziej kompleksową i wiarygodną charakterystykę jego skuteczności i stabilności. W tabeli 31 przedstawiono wyniki ewaluacji modelu uzyskane dla 1000 iteracji bootstrapowych.

Tabela 31. Ewaluacja modelu predykcji ElasticNet

Metryka	95% Przedział ufności
MAE	0,015 – 0,025 [kG/cm²]
R^2	0,850 – 0,954 [-]

Wyznaczone przedziały ufności wskazują, że średni błąd bezwzględny modelu utrzymuje się na niskim poziomie niezależnie od składu wylosowanych danych treningowych. Jednocześnie uzyskane wartości współczynnika determinacji potwierdzają wysoką zgodność prognoz z wartościami obserwowanymi, wskazując na stabilność działania modelu w warunkach wielokrotnego próbkowania bootstrapowego. Otrzymane wyniki potwierdzają, że model ElasticNet zapewnia dobre dopasowanie do analizowanych danych oraz charakteryzuje się wysoką powtarzalnością uzyskiwanych rezultatów.

Zaprezentowane wyniki dowodzą, iż integracja danych procesowych z rezultatami inspekcji optycznej umożliwia predykcję jakości opakowań. Zgrzewarki automatyczne często stanowią systemy zamknięte, w których odczyt parametrów procesu w czasie rzeczywistym jest niemożliwy lub ograniczony do podstawowych danych o liczbie wykonanych cykli. W tego typu uwarunkowaniach prognozowanie jakości wykonanego połączenia oparte wyłącznie na danych z systemu hybrydowej inspekcji stanowi jedyne dostępne rozwiązanie. W celu oceny możliwości implementacji takiego modelu, powtórzono opisaną wyżej procedurę uczenia modeli regresyjnych z zastosowaniem zagnieżdżonej walidacji krzyżowej (w schemacie 5 × 3). W procesie tym wykorzystano cztery predyktory bazujące na wynikach inspekcji: średniej i maksymalnej temperaturze w obszarze zgrzewania oraz liczbie wad w postaci zmarszczek i zagnieceń przy wysokiej temperaturze. W tabeli 32 przedstawione zostały rezultaty uzyskane dla pięciu modeli regresji w przewidywaniu wartości wyniku testu ciśnieniowego. Spośród ocenianych modeli jedynie regresja Lasso osiągnęła znaczący poziom zgodności predykcji ($R^2 = 0,407$). Chociaż nie jest to rezultat umożliwiający zastosowanie modelu w praktyce, pokazuje, że regresja Lasso wyjaśnia znaczną część wariancji w porównaniu z innymi ocenianymi modelami.

Tabela 32. Porównanie modeli predykcji jakości zgrzewu na podstawie wyników inspekcji

Model	MAE [kG/cm²]	RMSE [kG/cm²]	R^2 [-]
ElasticNet	0,052	0,066	0,407
Ridge	0,061	0,072	0,295
Lasso	0,059	0,075	0,232
SVR	0,065	0,085	0,018
RandomForest	0,067	0,087	-0,028

Zastosowane predyktory wykazują obiecujący potencjał w aspekcie zwiększenia zdolności predykcyjnych modelu po pozyskaniu obszerniejszego zbioru danych uczących. Wskazuje to, że w przyszłości, przy większej ilości danych, informacje wizyjne mogą nie tylko skutecznie uzupełniać parametry procesowe, ale także być stosowane niezależnie do predykcji jakości. Kompleksowa weryfikacja efektywności proponowanego rozwiązania wymaga jednak ewaluacji na większej liczbie próbek, co zostanie przeprowadzone w ramach pilotażowego wdrożenia hybrydowego systemu inspekcji w realnych warunkach produkcyjnych.

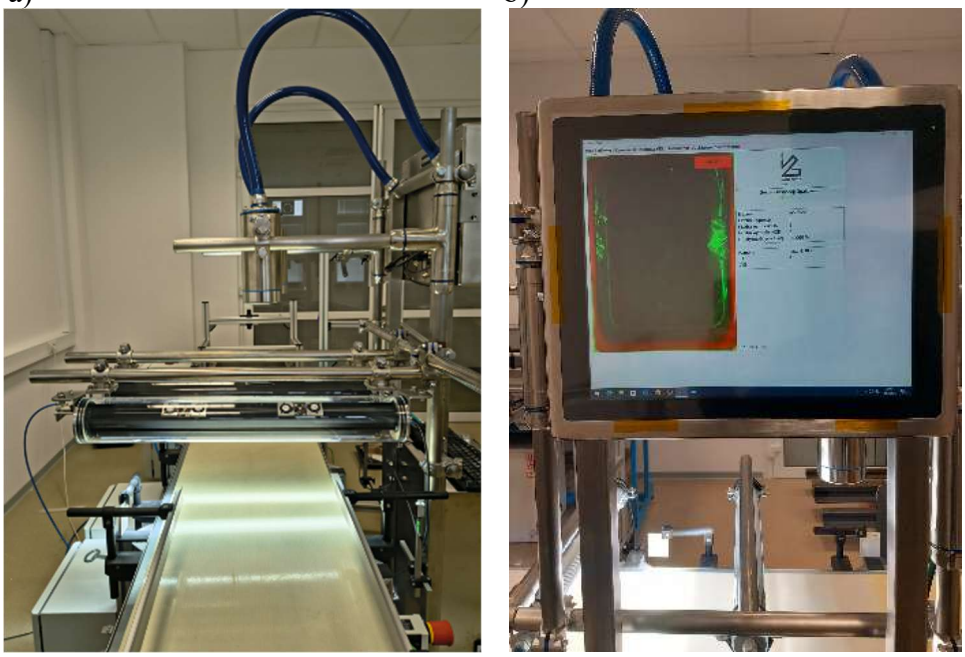
5. Wytworzenie i weryfikacja wersji prototypowej systemu

W kolejnym etapie prac rozwojowych opracowano i wytworzono prototypową wersję hybrydowego systemu inspekcji opakowań zgrzewanych termicznie. W celu zapewnienia warunków zbliżonych do rzeczywistego procesu produkcyjnego, system zintegrowano z transporterem przemysłowym, umożliwiając prowadzenie badań w środowisku odpowiadającym docelowej aplikacji. Tak przygotowane stanowisko pozwoliło na realizację testów typu oraz przeprowadzenie niezbędnej parametryzacji systemu przed wdrożeniem u użytkownika końcowego. Podejście to zminimalizowało ryzyko wystąpienia problemów w trakcie późniejszej eksploatacji, umożliwiając wykrycie i wyeliminowanie potencjalnych błędów oraz niezgodności już na etapie testów prototypu.

5.1. Implementacja hybrydowej metody inspekcji opakowań

Na podstawie wyników badań modelowych układów obrazowania, wykonana została docelowa konstrukcja systemu inspekcji (Rys. 96a). W celu spełnienia norm bezpieczeństwa obowiązujących w przedsiębiorstwach z branży spożywczej poszczególne podzespoły wykonano ze stali nierdzewnej. Ponadto, wytypowane oświetlacze LED, panel operatora, skrzynka elektryczna oraz obudowy kamer posiadają klasę szczelności IP69K umożliwiającą mycie strumieniem wody o zwiększonym ciśnieniu. Operator urządzenia ma możliwość obsługi systemu za pomocą monitora dotykowego (Rys. 96b).

a) b)



Rys. 96. Wersja prototypowa systemu inspekcji a) widok ogólny b) panel HMI

Projekt konstrukcyjny systemu opracowano w oparciu o wytyczne normy PN-EN 1672-2, ze szczególnym uwzględnieniem kryteriów łatwości czyszczenia i konserwacji. Uwzględniając specyfikę środowiska przemysłu spożywczego oraz stosowanie agresywnych środków dezynfekujących, elementy nośne, obudowy oraz osłony instalacji kablowej wykonano z materiałów o wysokiej odporności chemicznej i korozyjnej. W przypadku kamery termowizyjnej (Rys. 97a), konieczne było zastosowanie osłony czołowej wykonanej z materiału (Rys. 97b), który zapewnia wysoką transmisyjność w zakresie podczerwieni długofalowej.

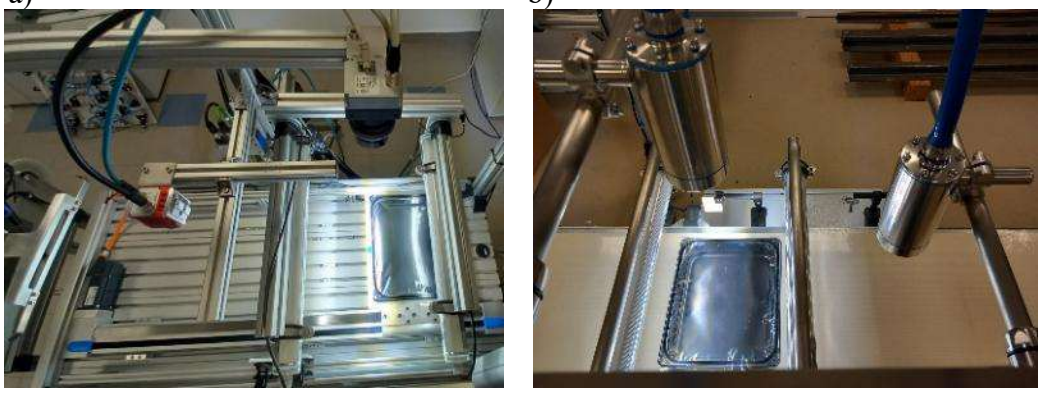
a) b)



Rys. 97. Moduł inspekcji IR a) kamera termowizyjna b) obudowa z osłoną czołową.

Wykonana konstrukcja charakteryzuje się dużą elastycznością w zakresie rekonfiguracji modułów i modyfikacji geometrii ustawień. Zastosowany system montażu kamery pozwala na zmianę ich pozycji w dwóch osiach a także obrót. Dzięki temu możliwe jest dostosowanie systemu do różnych konfiguracji linii przemysłowych. Ze względu na konstrukcję wykorzystanego do testów transportera, konieczna była zmiana kolejności kamer względem wersji modelowej. (Rys. 98a). W prototypie, pierwsze zdjęcie wykonywane jest przez kamerę pasma widzialnego, a następnie przez kamerę termowizyjną (Rys. 98b).

a) b)



Rys. 98. Kolejność układów obrazowania a) wersja modelowa b) prototyp

Ponadto, w wersji przemysłowej zastosowano kamerę IR wyposażoną w obiektyw o długości ogniskowej wynoszącej f=13 mm. Umożliwiło to ograniczenie efektu dystorsji, względem wersji modelowej. Parametry zmodyfikowanego toru wizyjnego przedstawione zostały w tabeli 33. Zastosowanie standardowego obiektywu umożliwiło zwiększenie jasności

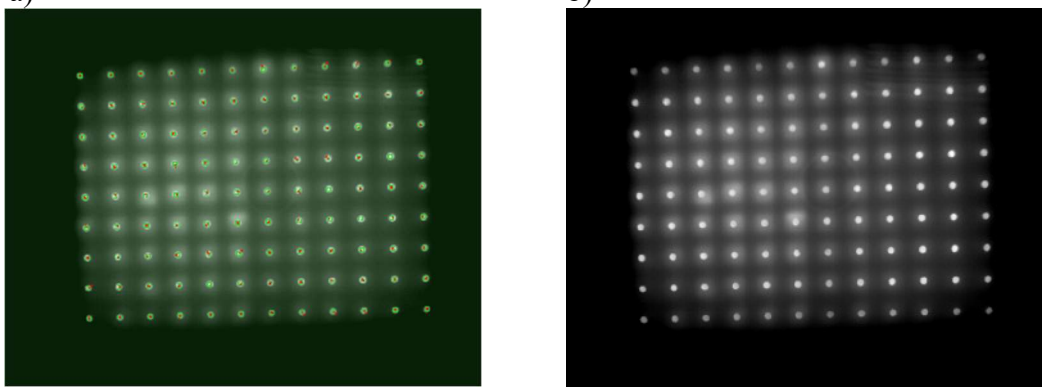
układu optycznego. Wartość przysłony wyniosła F/1.25, w porównaniu z F/1.4 w rozwiązaniu modelowym.

Tabela 33. Parametry toru wizyjnego IR

Wymiary sensora	10.9 x 8.12 mm
Rozmiar piksela	17 µm
Rozdzielczość sensora	640 x 480 px
Ogniskowa obiektywu	13 mm
Przysłona obiektywu	F/1.25

Po ponownym przeprowadzeniu procesu kalibracji, wyznaczona została mapa rektyfikacji obrazu, która umożliwiła korekcję zniekształceń optycznych (Rys. 99b).

a) b)



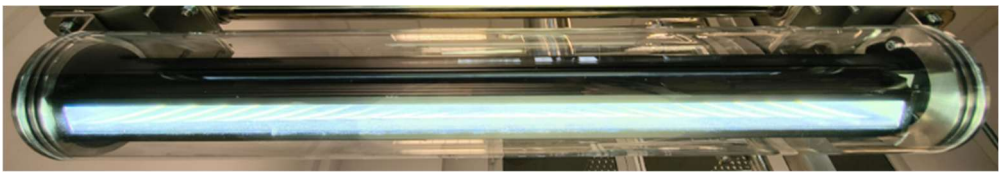
Rys. 99. Kalibracja toru IR prototypu a) przykładowy obraz wzorca z wektorami błędów b) obraz po procesie rektyfikacji

Wyznaczone parametry modelu kamery IR przedstawione zostały w tabeli 34. Średni błąd reprojekcji wyniósł 0,15 piksela. Warto zauważyć, że wyznaczone współczynniki dystorsji radialnej były znacząco niższe niż w przypadku kamery zastosowanej w wersji modelowej systemu.

Tabela 34. Wyznaczone parametry wewnętrzne modelu kamery IR w prototypie systemu

Parametr	Wartość
Średni błąd reprojekcji (RMS)	0,15 [px]
Współrzędna X punktu głównego	337,98 [px]
Współrzędna Y punktu głównego	263,64 [px]
Dystorsja obiektywu K1	-23,9e-4
Dystorsja obiektywu K2	32,9e-2
Dystorsja obiektywu P1	-39,7e-3
Dystorsja obiektywu P2	99,0e-4
Dystorsja obiektywu K3	-20,1e-2
Dystorsja obiektywu K4, K5, K6	0

W prototypowej wersji urządzenia zastosowano dedykowane dla przemysłu spożywczego oświetlacze liniowe posiadające certyfikat IP69K (Rys. 100).



Rys. 100. Oświetlacz liniowy dedykowany do przemysłu spożywczego

W celu określenia właściwej konfiguracji kątowej oświetlaczy przeprowadzono badania z wykorzystaniem metody planowania eksperymentów DOE (*ang. Design of Experiments*) [207]. Podejście to umożliwia jednoczesne badanie wpływu wszystkich czynników wejściowych oraz ich wzajemnych interakcji na zmienną zależną. W obszarze systemów wizyjnych było stosowane m.in. do:

- optymalizacji konfiguracji parametrów przetwarzania i analizy obrazów [208],
- zwiększenia dokładności i powtarzalności procesu kalibracji kamery [209],
- optymalizacji oświetlenia i toru wizyjnego w celu minimalizacji błędów pomiarowych [210].

Przeprowadzone badania miały na celu optymalizację układu obrazowania w paśmie widzialnych w celu osiągnięcia wysokiej jakości rejestrowanych obrazów. Czynniki wykorzystane w eksperymencie to kąt nachylenia, przysłona obiektywu oraz zastosowanie filtru polaryzacyjnego (Tab. 35). Jako zmienną zależną przyjęto wskaźnik jakości HQ.

Tabela 35. Parametry eksperymentu

Czynnik	Opis	Poziomy
A	Kąt nachylenia oświetlaczy	35˚, 55˚
B	Przysłona	F2.2, F2.8
C	Filtr	Brak, Polaryzacyjny

Podczas zrealizowanych prac wykorzystane zostało specjalistyczne oprogramowanie statystyczne Minitab. W przeprowadzonym eksperymencie wykorzystano randomizację [211], która polega na losowym przyporządkowaniu ustawień poziomów czynników w kolejnych doświadczeniach. Dzięki losowej kolejności wykonywania poszczególnych prób zmniejszone zostaje ryzyko wpływu czynników zakłócających na uzyskane wyniki. Poprzez zastosowanie takiego planu badań możliwe jest wyciągnięcie prawidłowych wniosków statystycznych na podstawie zgromadzonych danych. W oprogramowaniu Minitab automatycznie losowana jest kolejność wykonania, czyli uporządkowana sekwencja kombinacji czynników w planie eksperymentalnym. W wygenerowanym eksperymencie rozróżniane są dwa porządki prób: kolejność standardowa oraz kolejność wykonania [212]:

- Kolejność standardowa - odpowiada sekwencji wynikającej z układu standardowego, najczęściej zgodnego z klasycznym porządkiem Yatesa stosowanym w planach czynnikowych.

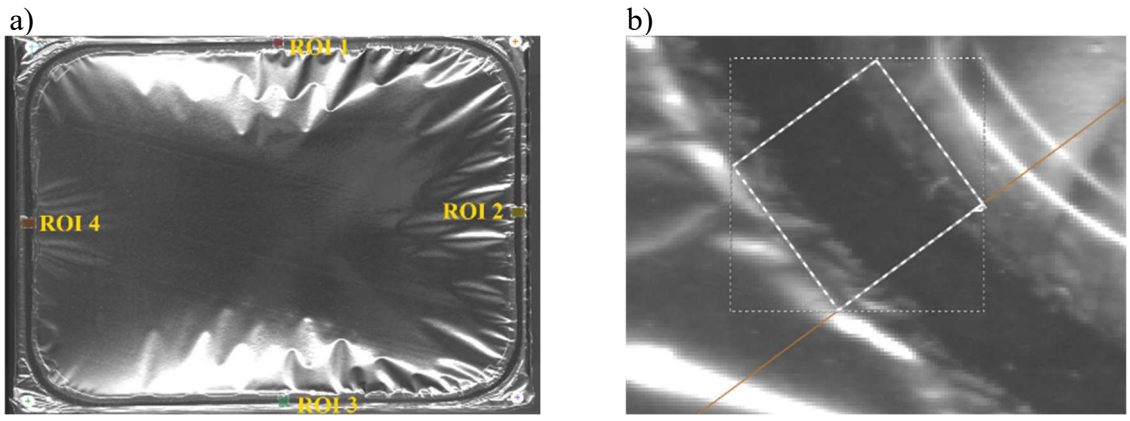
- Kolejność wykonania - jest natomiast sekwencją zrandomizowaną, którą należy ściśle stosować podczas realizacji eksperymentu, aby ograniczyć wpływ błędów systematycznych.

Plan eksperymentu został przedstawiony w tabeli 36. Eksperyment obejmuje trzy czynniki: ciągły czynnik A, którego zakres wynosi od 35˚ do 55˚, z punktem centralnym na poziomie 45˚, oraz dwa czynniki kategoryczne B i C, z których każdy ma dwa poziomy.

Tabela 36. Plan eksperymentu czynnikowego

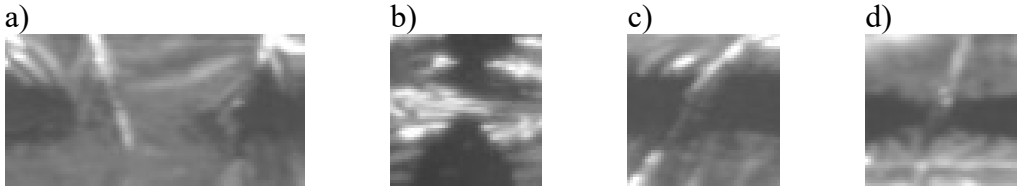
Kolejność standardowa	Kolejność wykonania	Czynnik A (Kąt)	Czynnik B (Przysłona)	Czynnik C (Filtr)
16	1	45˚	F/2.8	Polaryzacyjny
15	2	45˚	F/2.2	Polaryzacyjny
4	3	55˚	F/2.8	Brak
12	4	45˚	F/2.8	Polaryzacyjny
2	5	55˚	F/2.2	Brak
14	6	45˚	F/2.8	Brak
13	7	45˚	F/2.2	Brak
5	8	35˚	F/2.2	Polaryzacyjny
7	9	35˚	F/2.8	Polaryzacyjny
8	10	55˚	F/2.8	Polaryzacyjny
1	11	35˚	F/2.2	Brak
9	12	45˚	F/2.2	Brak
10	13	45˚	F/2.8	Brak
11	14	45˚	F/2.2	Polaryzacyjny
3	15	35˚	F/2.8	Brak

Podczas badań wykorzystano dwie próbki opakowań. Pierwszą, pozbawioną wad, przeznaczono do oceny jakości obrazu w obszarze prawidłowo wykonanego połączenia zgrzewanego. W tym celu wyznaczono ROI w górnej, dolnej, lewej i prawej części obrazu (Rys. 101a) oraz cztery obszary zlokalizowane w okolicy przekątnych opakowania (Rys. 101b).



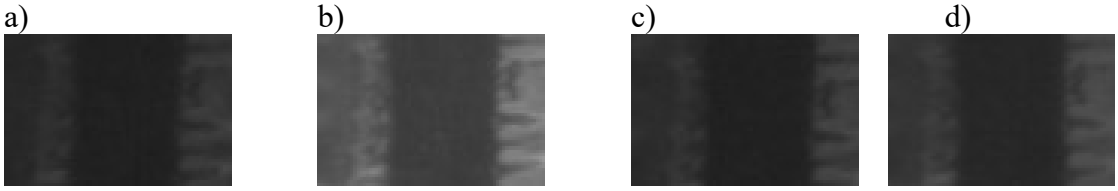
Rys. 101. Obszary oceny jakości obrazu próbki nr 1 a) ROI 1-4 b) przykład ROI 5-8

Na obrazie drugiej próbki wyznaczono obszary czterech wad (Rys. 102).



Rys. 102. Obszary użyte do oceny obrazu próbki nr 2 a) ROI 1 b) ROI 2 c) ROI 3 d) ROI 4

W zależności od zastosowanych poziomów czynników, podczas kolejnych eksperymentów uzyskiwane były obrazy o zróżnicowanej jakości (Rys. 103).



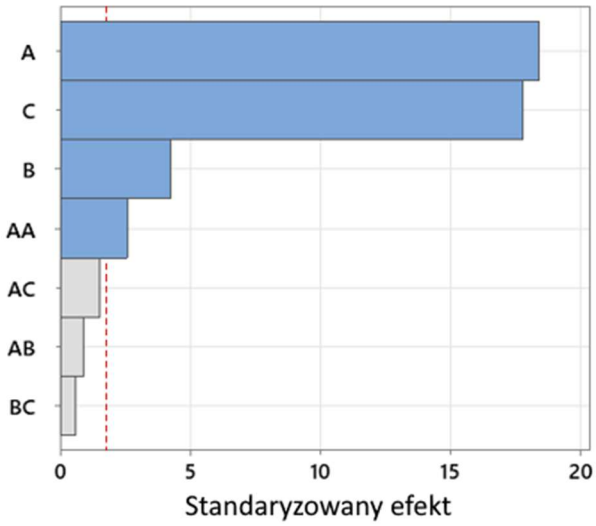
Rys. 103. Obrazy próbki 1 zarejestrowane podczas eksperymentu a) nr 1 b) nr 5 c) nr 10 d) nr 16

Analogicznie jak w przypadku analizy obrazów syntetycznych podczas modelowania układów obrazowania, całkowity wskaźnik jakości THQ obrazów obliczono jako średnią harmoniczną uzyskanych wyników (Tab. 37). Dzięki takiemu zabiegowi obszary o najniższej wartości wywierają większy wpływ na końcową ocenę układu obrazowania.

Tabela 37. Wyniki uzyskane podczas eksperymentu

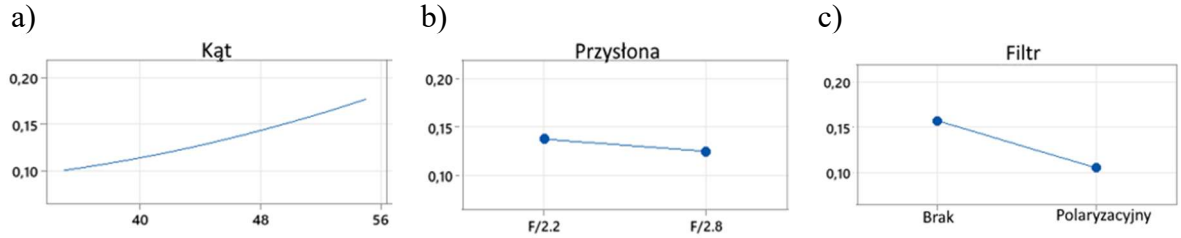
Kolejność standardowa	Kolejność wykonania	Wskaźnik HQ próbka 1	Wskaźnik HQ próbka 2	Całkowity wskaźnik THQ
16	1	0,09	0,12	0,10
15	2	0,09	0,13	0,10
4	3	0,17	0,23	0,19
12	4	0,09	0,12	0,10
2	5	0,20	0,24	0,22
14	6	0,14	0,19	0,16
13	7	0,14	0,20	0,16
5	8	0,07	0,10	0,08
7	9	0,07	0,08	0,07
8	10	0,12	0,16	0,14
1	11	0,12	0,15	0,13
9	12	0,14	0,19	0,16
10	13	0,13	0,16	0,14
11	14	0,10	0,13	0,11
3	15	0,10	0,13	0,12
6	16	0,14	0,18	0,16

Na podstawie analizy wyników określony został wpływ czynników głównych oraz ich wzajemnych interakcji na zmienną zależną THQ (Rys. 104). Czerwona linia oznacza wartość progową efektu przy poziomie istotności 0,10. Szare słupki obrazują zmienne nieistotne, które wykluczono z modelu. Symbol AA wskazuje na efekt kwadratowy, co świadczy o nieliniowym charakterze wpływu tego czynnika na zmienną zależną.



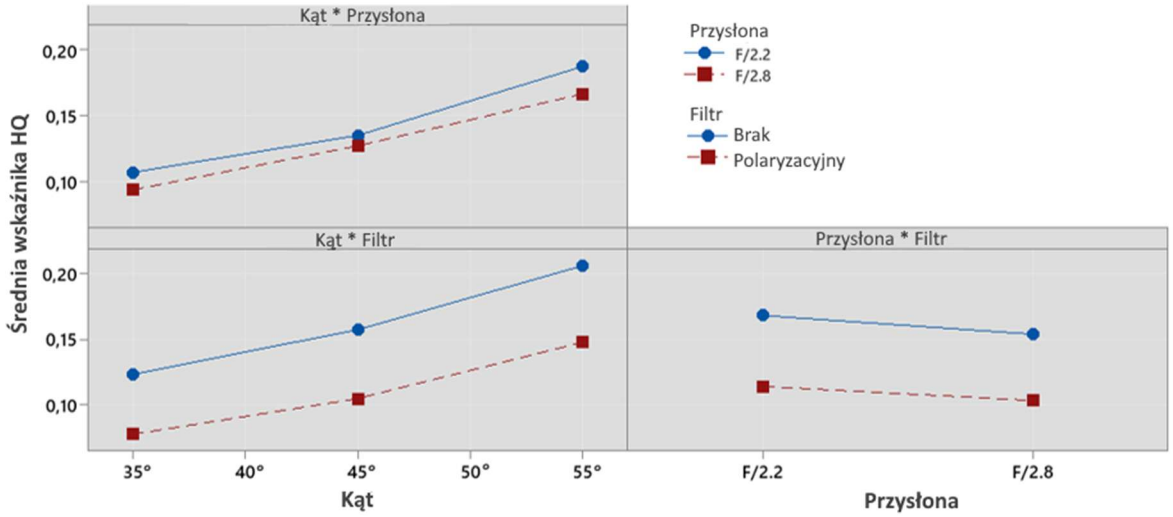
Rys. 104. Wykres wpływu czynników na zmienną zależną

Na wykresach poniżej przedstawiony wpływ pojedynczych czynników. Zgodnie z wcześniej przeprowadzonymi symulacjami komputerowymi wzrost wartości kąta oświetlaczy prowadzi do poprawy jakości rejestrowanych obrazów (Rys. 105a). Negatywny wpływ ma zmiana przysłony z F/2.2 na F/2.8 (Rys. 105b). Zastosowanie filtra polaryzacyjnego wywołuje spadek jasności, co przekłada się na obniżenie wskaźnika HQ (Rys. 105c).



Rys. 105. Wpływ głównych czynników na wskaźnik HQ a) kąt oświetlaczy b) przysłona c) filtr

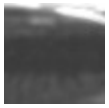
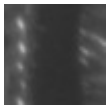
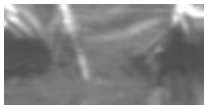
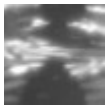
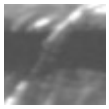
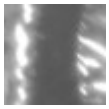
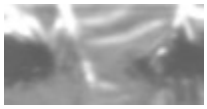
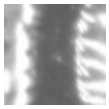
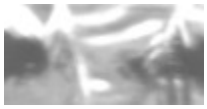
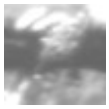
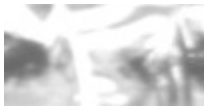
Główne efekty obrazują jednostkowy wpływ danej zmiennej na zmienną zależną, uśredniony po wszystkich poziomach pozostałych czynników uwzględnionych w planie eksperymentów. Z kolei wykresy interakcji (Rys. 106) służą do weryfikacji, czy wpływ jednego czynnika na zmienną objaśnianą jest modyfikowany przez poziom innego czynnika. W sytuacji, gdy linie na wykresie przebiegają równolegle, można stwierdzić brak istotnej interakcji.



Rys. 106. Interakcje pomiędzy czynnikami

Na podstawie uzyskanych rezultatów w zbadanym zakresie zmienności czynników najwyższą wartość wskaźnika THQ uzyskano dla kąta oświetlaczy wynoszącego 55˚, przysłonie F/2.2 oraz braku filtra polaryzacyjnego. W kolejnym kroku, w celu poprawy jakości obrazów, w przeprowadzonych próbach zwiększano wartość kąta oświetlaczy w krokach co 5°, aż do osiągnięcia wartości 70°. Jak można zaobserwować na zarejestrowanych obrazach (Tab. 38), zgodnie z wyznaczoną zależnością wraz ze wzrostem wartości wskaźnika THQ ulegała poprawie. Jednak powyżej kąta wynoszącego 65° nastąpił znaczący spadek wartości tego wskaźnika, wynikający z silnego odbicia kierunkowego.

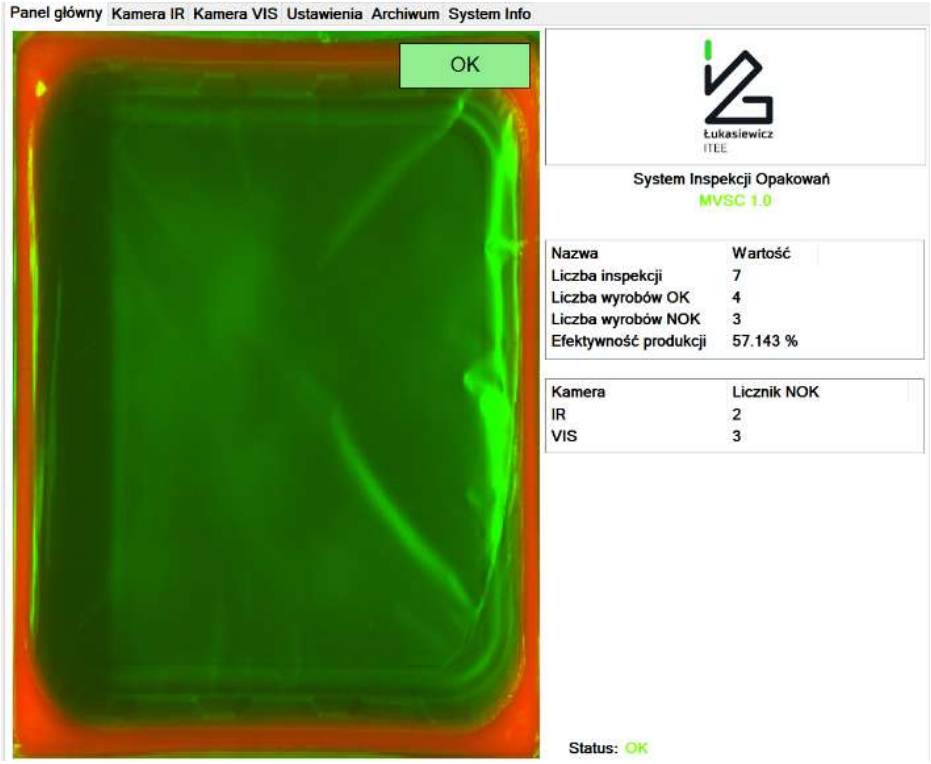
Tabela 38. Jakość obrazów w zależności od kąta nachylenia oświetlaczy

Kąt	Próbka 1 ROI 1	Próbka 1 ROI 6	Próbka 2 ROI 1	Próbka 2 ROI 2	Próbka 2 ROI 3	Próbka 2 ROI 4	Wskaźnik THQ
55˚							0,22
60˚							0,24
65˚							0,25
70˚							0,19

Negatywny wpływ zwiększenia kąta nachylenia oświetlaczy powyżej 65˚ był szczególnie zauważalny w obszarze ROI 6 dla próbki 1 oraz w ROI 1 i ROI 3 dla próbki 2. W pierwszym przypadku powstałe refleksy istotnie obniżyły kontrast, co ma negatywny wpływ na

skuteczność algorytmu detekcji obszaru zgrzewu. Analiza próbki 2 wykazała, że zbyt duży kąt nachylenia oświetlaczy może prowadzić do fałszywych detekcji w miejscach prawidłowo wykonanego połączenia zgrzewanego, a także ograniczać klasyfikację wad z powodu utraty informacji wywołanej saturacją pikseli. Na podstawie rezultatów wykonanych eksperymentów identyfikacyjnych wytypowano docelowe parametry układu obrazowania: kąt nachylenia oświetlaczy 65°, przysłona F/2.2 oraz brak filtra optycznego.

W wytypowanym środowisku programistycznym Aurora Vision Studio, opracowano ogólną strukturę programu, w tym interfejs graficzny użytkownika oraz moduł archiwizacji danych pochodzących z układów obrazowania. Przykładowy widok interfejsu opracowanej aplikacji przedstawiono na rysunku (Rys. 107).



Rys. 107. Program dedykowany do hybrydowej inspekcji opakowań zgrzewanych termicznie

W ramach przeprowadzonych badań zaimplementowano algorytmy fuzji obrazu oraz automatycznej klasyfikacji defektów. Na podstawie wyników predykcji opracowanego modelu wykonywana jest binarna ocena jakości każdego opakowania. Rezultat klasyfikacji przyjmuje formę dwustanowej zmiennej wyjściowej. Status zgodności (OK) określa jednostkę wykonaną prawidłowo, natomiast status niezgodności (NOK) wskazuje na obecność wad, kwalifikujących opakowanie do automatycznego odrzutu z procesu produkcyjnego.

5.2. Ewaluacja prototypowego systemu inspekcji

Istotnym etapem wdrożenia systemu inspekcji jest zaplanowanie, wykonanie i ewaluacja testów FAT (*ang. Factory Acceptance Tests*) opracowanego prototypu. Ich celem jest zminimalizowanie ryzyka wystąpienia usterek i błędów funkcjonalnych podczas testów SAT (*ang. Site Acceptance Tests*) urządzenia w miejscu instalacji [213].

Walidacja systemu inspekcji odbywa się zazwyczaj poprzez wykonanie następujących testów sprawdzających [214]:

- dokładność wyników inspekcji,
- niezawodność wyników inspekcji,
- przepustowość,
- poprawność i niezawodność zbierania danych.

Istnieje wiele norm określających ilościową ocenę wizyjnych systemów pomiarowych, w których jako podstawowy parametr wykorzystuje się niepewność pomiaru. Na tej podstawie możliwe jest określenie, czy dany system jest odpowiedni do realizacji konkretnego zadania pomiarowego. W przypadku systemów wizyjnych, których wyniki mają charakter zmiennych atrybutowych, należy stosować inne procedury umożliwiające ocenę ich zdolności klasyfikacyjnej. Jedną z nielicznych norm dedykowanych systemom wizyjnym jest VDI/VDE/VDMA 2632 [215]. Część 3 wytycznych opisuje testy odbiorcze dla systemów wizyjnych realizujących klasyfikację. Obejmuje między innymi cechy pozwalające rozróżniać kluczowe wskaźniki zdolności klasyfikacyjnej, takie jak współczynnik detekcji czy współczynnik fałszywych alarmów, a także informacje dotyczące statystyk produkcyjnych.

Podstawową metodą weryfikacji klasyfikacyjnych systemów wizyjnych są testy z wykorzystaniem przykładowych obiektów inspekcji. Powinny one być wykonane na reprezentatywnej grupie wyrobów. Selekcja próbek uzgadniana jest pomiędzy zamawiającym system inspekcji i producentem. Metoda ta jest szczególnie wskazana podczas testów FAT, gdy liczba próbek jest ograniczona oraz gdy analityczne zdefiniowanie wad i cech obiektów inspekcji jest niemożliwe lub nie gwarantuje wystarczająco precyzyjnego opisu dla wszystkich przypadków.

Jedną ze stosowanych w przemyśle metod oceny systemów wizyjnej inspekcji jest analiza zgodności atrybutów AAA (*ang. Attribute Agreement Analysis*). Do podstawowych metryk oceny skuteczności systemu inspekcyjnego zalicza się zgodność wyników inspekcji z wartością referencyjną *(ang. Ground Truth*). W celu przypisania analizowanym próbkom odpowiednich klas, z którymi następnie porównywane są wyniki uzyskane przez system inspekcyjny, wykorzystuje się ocenę ekspercką. Wyniki tej oceny stanowią wartość referencyjną, względem której określana jest zgodność klasyfikacji dokonanej przez system [216].

Podstawowym zadaniem systemu opracowanego inspekcji jest wykonanie klasyfikacji binarnej, podczas której produkty oceniane są jako prawidłowo wykonane (*ang. OK/Pass/Accept*) lub wadliwie (*ang. NOK/Fail/Reject*). Rezultat inspekcji przesyłany jest

następnie do modułu wyrzutnika, którego zadaniem jest usunięcie wyrobów z wadami z linii produkcyjnej. Metodyka przeprowadzania badania AAA składa się z kilku etapów [217]:

- należy wybrać co najmniej 20 wyrobów (zaleca się większą liczbę, zwykle od 20 do 30), które reprezentują pełne spektrum zmienności procesu,
- należy wyznaczyć eksperta (*ang. Master Appraiser*), który określi rzeczywistą kategorię każdego badanego wyrobu,
- należy wybrać liczbę kontrolerów oraz liczbę powtórzeń,
- kontrolerzy oceniają (klasyfikują) każdą część niezależnie i w losowej kolejności, bez znajomości wyników eksperta, a następnie zapisują wyniki klasyfikacji w arkuszu danych,
- analiza rezultatów obejmująca powtarzalność indywidualną, zgodność ze standardem, zgodność między kontrolerami.

Do ewaluacji systemu inspekcji wizyjnej należy określić kryteria decyzyjne. Standardowe wartości dla poszczególnych miar zostały przedstawione w tabeli 39.

Tabela 39.Kryteria decyzyjne ewaluacji systemu inspekcji [218]

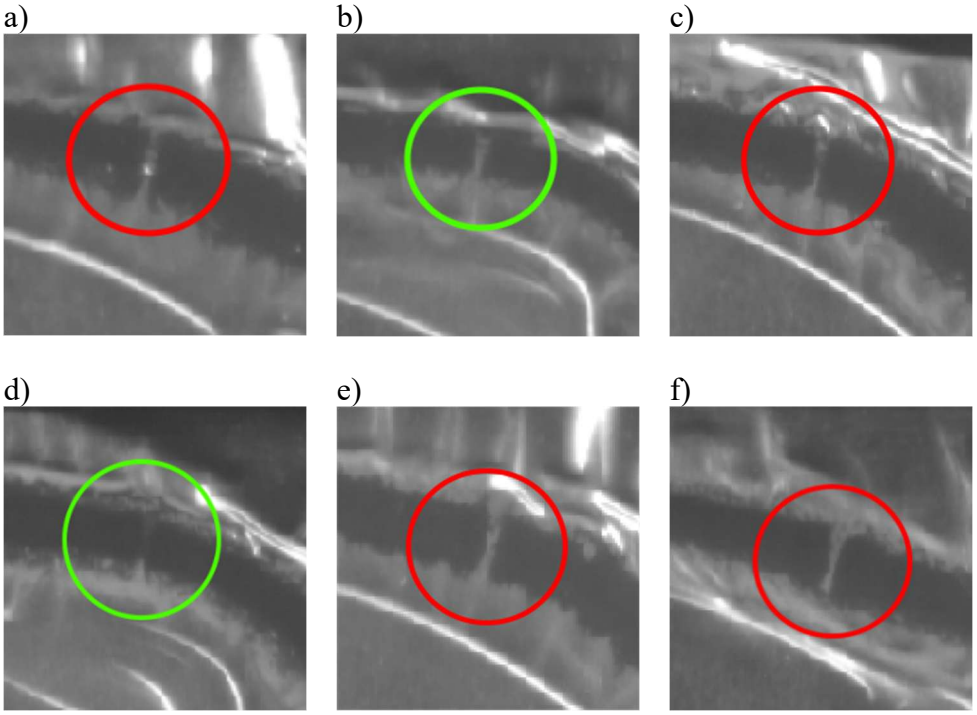
Metryka	Poziom doskonały	Poziom akceptowalny	Poziom nieakceptowalny
Zgodność systemu inspekcji z oceną eksperta	Powyżej 90%	Od 80% do 90%	Poniżej 80%
Wskaźnik fałszywie pozytywnych prób OK/NOK (*ang. false positive rate*)	Poniżej 2%	Od 2% do 5%	Powyżej 5%
Wskaźnik fałszywych alarmów NOK/OK (*ang. false discovery rate*)	Poniżej 5%	Od 5% do 10%	Powyżej 10%
Powtarzalność rezultatów inspekcji systemu	Powyżej 90%	Od 80% do 90%	Poniżej 80%

Zgodnie z opisaną procedurą przygotowane zostały próbki opakowań, które po procesie zgrzewania zostały poddane inspekcji przez opracowany system. Na podstawie ocen eksperta 10 opakowań sklasyfikowanych zostało jako prawidłowo wykonane, natomiast pozostałe 20 uznano za wadliwe. Dwa spośród opakowań ocenione zostały jako na granicy akceptacji. Celem przeprowadzonych badań było określenie odpowiedniego poziomu czułości systemu inspekcji, który z jednej strony zapewniał wysoką skuteczność detekcji i zgodność z ocenami eksperta, a z drugiej pozwalał utrzymać współczynnik fałszywych alarmów na akceptowalnym poziomie, niezakłócającym procesu produkcyjnego. W tabeli 40 przedstawione zostały rezultaty wyników inspekcji za pomocą opracowanego systemu w porównaniu do wartości referencyjnych.

Tabela 40. Ewaluacja opracowanego systemu inspekcji

Metryka	Liczba opakowań	Udział procentowy
Zgodność systemu inspekcji z oceną eksperta	27	90 %
Wskaźnik fałszywie pozytywnych prób OK/NOK	1	3,33 %
Wskaźnik fałszywych alarmów NOK/OK	2	6,67 %

Jedyny przypadek rezultatu inspekcji który nie był zgodny z wartością referencyjną stanowiła powtarzająca się niewielka wada (Rys. 108a), wynikająca z miejscowego uszkodzenia płyty grzewczej. W zależności od parametrów procesu zgrzewania była ona mniej lub bardziej widoczna na zarejestrowanych obrazach. Klasyfikacja tego obszaru była również utrudniona dla ekspertów. W jednym przypadku, określonym jako granica akceptacji, uznano produkt za prawidłowy (Rys. 108b), a w drugim wadliwy (Rys. 108c). Dla pozostałych próbek testowych ocena eksperta w tym obszarze była zgodna z systemem inspekcji.



Rys. 108. Przykłady klasyfikacji ekspertów i systemu inspekcji a) NOK/OK b) OK/OK c) NOK/NOK d) OK/OK e) NOK/NOK

Wykonany został również test powtarzalności rezultatów inspekcji. Ze względu na specyfikę opracowanej metody inspekcji wykorzystującej analizę obrazów termowizyjnych, nie było możliwe ponowne wykonanie rejestracji obrazów próbki w tych samych warunkach. Analizie poddano obrazy próbek ponownie skontrolowanych w odstępie czasu wynoszącym ok. 7 sekund. Powtarzalność uzyskanych rezultatów inspekcji wyniosła 87%. Wzrosła natomiast wartość wskaźnika fałszywych alarmów do 10%. Ponadto jedno wadliwe

opakowanie zostało dodatkowo błędnie sklasyfikowane. Jest to spodziewanym rezultatem ze względu na spadek temperatury połączenia zgrzewanego podczas inspekcji, a tym samym zmniejszenie poziomu sygnału do szumu.

Przepustowość systemu została zweryfikowana podczas próby polegającej na ciągłej inspekcji 30 opakowań. Na podstawie uzyskanych wyników w oprogramowaniu wyznaczono czasy wykonywania poszczególnych algorytmów oraz inferencji wykorzystanego modelu klasyfikacji. Eksperymenty weryfikacyjne przeprowadzono z wykorzystaniem komputera przemysłowego, którego jednostkę centralną stanowił procesor Intel Core i7-9700 o taktowaniu bazowym 3,00 GHz. Za akceleracje obliczeń równoległych odpowiadał dedykowany układ graficzny NVIDIA GeForce RTX 2080 SUPER. W tabeli 41 przedstawione zostały średnie czasy wykonywania poszczególnych modułów algorytmu inspekcji. W zaimplementowanym rozwiązaniu zastosowano przetwarzane wielowątkowe oraz mechanizm buforowania obrazów. Dzięki temu dane z kamery VIS, IR są przetwarzane osobno i za pomocą kolejkowania wysyłane do wątku FUSION, w którym wykonywana jest analiza z wykorzystaniem opracowanego modelu uczenia głębokiego. W czasie wykonywania fuzji i klasyfikacji obrazów, wątki odpowiedzialne za akwizycję obrazów z kamery mogą realizować zadania w kolejnym cyklu pracy.

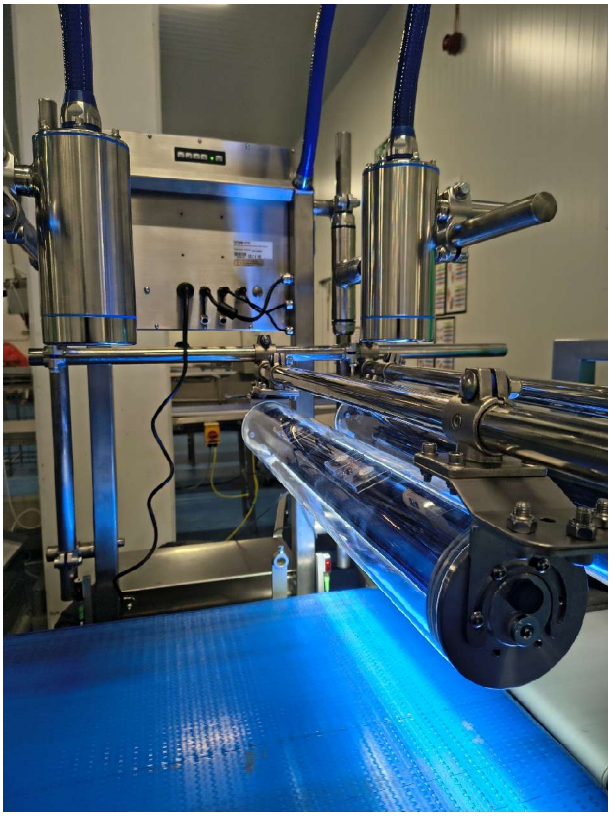
Tabela 41. Analiza wydajności systemu

Wątek	Czas wykonywania [ms]
IR	84
VIS	119
FUSION	424

Wykonana analiza wyników inspekcji wykazała zgodność systemu z kryteriami określonymi w procedurze FAT, co stanowi podstawę do dopuszczenia układu do testów integracyjnych w warunkach rzeczywistych. Wykazano, że czasy wykonywania algorytmów przetwarzania i analizy obrazów, zapewniają wymaganą przepustowość operacyjną systemu inspekcji. Zgodnie z obowiązującymi standardami przemysłowymi zaimplementowane oprogramowanie umożliwia jednoczesną archiwizację surowych obrazów z obu kamer oraz kompletnych wyników inspekcji. Zastosowane rozwiązanie gwarantuje pełną odtwarzalność historii kontroli poszczególnych opakowań, stanowiąc jednocześnie bazę danych przydatną podczas przyszłych prac nad rozwojem algorytmów inspekcji.

Po przeprowadzeniu testów funkcjonalnych obejmujących integrację mechaniczną, weryfikację układów elektrycznych, kalibrację torów wizyjnych oraz ocenę funkcjonalności oprogramowania potwierdzono poprawne działanie wszystkich modułów opracowanego systemu. Na podstawie wyników przeprowadzonej analizy technicznej, zgodnie z wewnętrznymi procedurami zarządzania innowacjami obowiązującymi w Łukasiewicz-ITeE, system hybrydowej inspekcji wdrożono jako rozwiązanie komercyjne przeznaczone dla przedsiębiorstw sektora przemysłu spożywczego. Istotnym elementem walidacji rynkowej oraz bezpośrednim rezultatem komercjalizacji wyników zrealizowanych prac badawczo-rozwojowych było pozyskanie zamówienia na dostawę i implementację systemu

hybrydowej inspekcji u jednego z wiodących producentów z branży przetwórstwa mięsnego (Rys. 109). Uzyskane doświadczenia wdrożeniowe, obejmujące zarówno aspekty techniczne, jak i organizacyjne, są podstawą do dalszego rozwoju i komercjalizacji rozwiązania. Zdobyta wiedza oraz kompetencje rozwinięte w trakcie realizacji projektu stanowią dla Łukasiewicz-ITeE podstawę do rozwoju działalności w nowym obszarze przemysłu, rozszerzając dotychczasową działalność jako producenta specjalistycznej aparatury badawczej i kontrolnej o rozwiązania dedykowane branży spożywczej.



Rys. 109. System hybrydowej optycznej inspekcji opakowań zgrzewanych termicznie zainstalowany w zakładzie produkcyjnym.

Zgodnie z wymaganiami odbiorcy końcowego opracowany system został zaprojektowany z uwzględnieniem wymagań stawianych nowoczesnym, zintegrowanym środowiskom produkcyjnym. W ramach dalszych prac rozwojowych planowana jest jego integracja z cyfrowym bliźniakiem procesu w celu zwiększenia efektywności produkcji oraz poprawy jakości wyrobów. Włączenie systemu hybrydowej optycznej inspekcji opakowań do cyfrowego modelu zakładu produkcyjnego umożliwi monitorowanie i analizę danych w czasie rzeczywistym, co bezpośrednio przełoży się na poprawę kluczowych wskaźników efektywności operacyjnej.

6. Podsumowanie

Współczesne systemy produkcyjne coraz częściej wymagają wdrażania rozwiązań umożliwiających kompleksową kontrolę wytwarzanych wyrobów. Ma to kluczowe znaczenie zarówno dla zapewnienia ich wysokiej jakości, jak i zwiększenia efektywności procesów produkcyjnych. Tendencja ta nabiera szczególnego znaczenia w kontekście rozwoju koncepcji zrównoważonej produkcji, ukierunkowanej na ograniczenie ilości powstających odpadów oraz racjonalne wykorzystanie zasobów. W tym kontekście hybrydowe metody obrazowania stanowią perspektywiczny i dynamicznie rozwijający się kierunek badań nad nowoczesnymi systemami inspekcji przemysłowej.

W pracy przedstawiono oryginalną metodę inspekcji wizyjnej oraz autorską aplikację dedykowaną do klasyfikacji wad opakowań zgrzewanych termicznie. Celem naukowym pracy było opracowanie hybrydowej metody inspekcji wykorzystującej fuzję obrazów z dwóch torów wizyjnych. W wymiarze utylitarnym skupiono się na praktycznej egzemplifikacji proponowanego rozwiązania na przykładzie kontroli opakowań zgrzewanych termicznie stosowanych w przemyśle spożywczym. Do osiągnięcia tak postawionego celu pracy, przeprowadzono szereg prac badawczych i rozwojowych.

W pierwszym etapie zrealizowanych badań wykonana została kompleksowa analiza aktualnego stanu wiedzy w zakresie zastosowania metod hybrydowych w systemach kontroli jakości oraz diagnostyki technicznej. W ramach przeprowadzonego przeglądu scharakteryzowano fizyczne podstawy funkcjonowania systemów kontroli wizyjnej, ze szczególnym uwzględnieniem mechanizmów oddziaływania promieniowania optycznego z materią. Dokonano również przeglądu i syntezy informacji zawartych w publikacjach naukowych oraz oficjalnych raportach dotyczących wykorzystania metod multimodalnych w procesach kontroli jakości i badaniach nieniszczących. Istotnym elementem analizy była systematyzacja i klasyfikacja stosowanych metod optycznych, a także ocena możliwości wykorzystania technik fuzji obrazów do integracji i efektywnego przetwarzania danych pochodzących z różnych torów wizyjnych. Przeprowadzona analiza pozwoliła na identyfikację aktualnych kierunków rozwoju oraz określenie potencjału metod hybrydowych w kontekście doskonalenia współczesnych systemów inspekcji przemysłowej. Eksperci wskazują na rosnące znaczenie systemów opartych na sztucznej inteligencji oraz metod hybrydowych jako kluczowych obszarów badań, ukierunkowanych na zwiększenie niezawodności procesów inspekcji oraz ograniczenie ryzyka błędnej klasyfikacji. Pomimo wyraźnego wzrostu liczby publikacji naukowych, nadal występują jednak istotne wyzwania ograniczające możliwość skutecznego przeniesienia tych rozwiązań do zastosowań przemysłowych. Utrzymująca się luka pomiędzy wynikami badań a ich praktycznym wdrożeniem wskazuje na konieczność prowadzenia dalszych prac badawczych mających na celu przezwyciężanie istniejących barier technologicznych i aplikacyjnych.

Zasadniczym elementem realizacji doktoratu wdrożeniowego były prace nad opracowaniem koncepcji systemu spełniającej przyjęte założenia projektowe. W procesie tym zastosowano metodę wspomagania decyzji opartą na wielokryterialnej macierzy decyzyjnej,

zdefiniowanych kryteriach oceny oraz przypisanych im wagach, zgodnie z metodą Pugha. Jako najbardziej istotne wskazano kryteria określające zdolność systemu do detekcji poszczególnych typów defektów. Następnie wprowadzono kryteria odnoszące się do jakości pozyskiwanych obrazów. Ponadto, uwzględniono kryteria zwiększające możliwości analityczne systemu, w szczególności zdolność do klasyfikacji oraz potencjalne korzyści synergiczne wynikające z integracji wielu układów obrazowania. Analiza uwzględniała również kryteria utylitarne, związane z gotowością technologiczną poszczególnych modułów obrazowania oraz kosztem ich wdrożenia. Zastosowane podejście umożliwiło systematyczne i metodyczne wyznaczenie konfiguracji układów wizyjnych. Istotną zaletą przyjętej metodyki jest identyfikacja rozwiązań alternatywnych, co ma szczególne znaczenie w procesie projektowania zaawansowanych systemów optomechatronicznych. Proces ten ma charakter iteracyjny, obejmujący możliwość wprowadzania modyfikacji sprzętowych i programowych na każdym etapie jego realizacji.

Na podstawie opracowanej koncepcji w kolejnym etapie prac przeprowadzono modelowanie poszczególnych układów obrazowania. W tym celu wykorzystano specjalistyczne oprogramowanie przeznaczone do cyfrowej symulacji przemysłowych systemów kontroli wizyjnej. Przeprowadzone analizy umożliwiły weryfikację podstawowych parametrów wytypowanych układów obrazowania. Ponadto wykonano badania symulacyjne mające na celu wyznaczenie kąta ustawienia oświetlaczy. Jak wykazano, parametr ten ma istotny wpływ na jakość rejestrowanych obrazów, a tym samym na zdolność systemu inspekcji do skutecznej i niezawodnej detekcji wad.

W kolejnym etapie prace ukierunkowane były na podniesienie poziomu gotowości technologicznej systemu inspekcji. Integracja układów obrazowania ze stanowiskiem badawczym umożliwiła przeprowadzenie szeregu badań w kontrolowanych warunkach laboratoryjnych i akwizycję reprezentatywnego zbioru obrazów próbek. W dalszej kolejności opracowana została metoda fuzji obrazów z kamery pasma widzialnego i podczerwieni. Ze względu na znaczące zniekształcenia optyczne układu obrazowania kamery termowizyjnej, konieczne było zastosowanie operacji rektyfikacji. W tym celu opracowany został wzorzec kalibracyjny, którego charakterystyczne punkty cechują się wysokim kontrastem zarówno w paśmie widzialnym jak również w podczerwieni. Kluczowym elementem na tym etapie było opracowanie autorskiej metody fuzji obrazów na potrzeby wysokowydajnej inspekcji. Po rejestracji wyrównane obrazy wykorzystywane są do generowania syntetycznych obrazów RGB, które łączą informacje o promieniowaniu cieplnym ze szczegółami tekstury zarejestrowanymi kamerą pasma widzialnego. W dalszej kolejności zweryfikowana została skuteczność detekcji i klasyfikacji wad na podstawie obrazów po procesie fuzji. Jak wykazano, opracowany model z wykorzystaniem głębokiego uczenia, umożliwił skuteczną detekcję i klasyfikację wad.

Istotnym zadaniem podczas realizacji doktoratu była integracja systemu z opracowanym stanowiskiem badawczym wyposażonym w manipulator przemysłowy, który wykorzystano do realizacji zautomatyzowanego procesu akwizycji obrazów w ściśle określonym reżimie czasowym. Utworzona baza danych procesowych oraz wyników inspekcji optycznej,

przeprowadzonej z wykorzystaniem systemu hybrydowego, umożliwiła wykonanie badań eksperymentalnych nad zastosowaniem metod uczenia maszynowego do predykcji jakości wykonanych połączeń zgrzewanych. Wykonana analiza wykazała, że możliwe jest określenie siły połączenia zgrzewanego na podstawie wyników bezkontaktowej inspekcji optycznej oraz podstawowych danych procesowych. Obecnie jedyną stosowaną metodą jest wykonanie badań niszczących. Jak wykazano, opracowane rozwiązanie może stanowić istotną innowację w obszarze systemów produkcyjnych, umożliwiającą uzupełnienie kontroli statystycznej o ciągłą predykcję poprawności wykonania połączeń zgrzewanych, realizowaną on-line w czasie rzeczywistym. Zaproponowana metoda wpisuje się w koncepcję Jakości 4.0, w której kluczowe znaczenie ma generowanie cyfrowych wątków danych dla każdego produktu, obejmujących m.in. parametry procesu, atrybuty produktu oraz ilościowe wskaźniki jakości. Co jest istotne dane te mogą być wykorzystywane do ciągłej optymalizacji i doskonalenia procesu produkcyjnego.

W ostatnim etapie prac wytworzono prototyp hybrydowego systemu inspekcji opakowań zgrzewanych termicznie. Dostosowanie opracowanego rozwiązania do norm obowiązujących w przemyśle spożywczym wymagało zastosowania odpowiednich materiałów konstrukcyjnych oraz zapewnienia wysokiego stopnia ochrony modułów wizyjnych. Urządzenie przystosowano do regularnego i gruntownego czyszczenia z użyciem środków chemicznych oraz mycia pod wysokim ciśnieniem. Dysponując w pełni funkcjonalnym prototypem systemu inspekcji, który został zintegrowany z transporterem przemysłowym, przeprowadzono optymalizację toru wizyjnego VIS, w celu uzyskania wysokiej jakości obrazów. Zastosowanie metody planowania eksperymentów DOE pozwoliło na wyznaczenie optymalnego kąta oświetlaczy względem osi głowicy wizyjnej, który ma istotny wpływ na jakość rejestrowanych obrazów.

Gotowość wdrożeniową systemu inspekcji ostatecznie potwierdziły testy FAT, które zostały zrealizowane przy udziale pracowników działu kontroli jakości użytkownika końcowego. Na podstawie reprezentatywnej grupy kontrolowanych wyrobów, wykonana została ich ogólna ocena z podziałem na wyroby prawidłowo wykonane oraz wadliwe. Na podstawie porównania wyników kontroli wykonanej przez ekspertów stwierdzono, że opracowane urządzenie realizuje zadanie inspekcji zgodnie z założeniami.

Konkludując, w ramach doktoratu wdrożeniowego osiągnięto cel pracy, opracowując oryginalną metodę hybrydowej inspekcji wizyjnej. Zrealizowanie planu badań umożliwiło metodyczne porównanie wariantów koncepcyjnych oraz opracowanie i wykonanie funkcjonalnego systemu hybrydowej optycznej inspekcji. Skuteczność wytrenowanego modelu klasyfikacji wad opakowań została potwierdzona na podstawie wydzielonego zbioru danych walidacyjnych. Pilotażowe wdrożenie systemu inspekcji w jednym z największych zakładów przetwórstwa mięsa drobiowego w Polsce stanowią podstawę dalszego rozwoju opracowanym rozwiązań sprzętowym i programowych. Rezultaty pracy doktorskiej mają duży potencjał do wykorzystania także w innych projektach realizowanych w Łukasiewcz-ITeE. Szczególnie rozwijany obecnie obszar, stanowią metody predykcji jakości dla zastosowań w przedsiębiorstwach produkcyjnych. Ponadto, zdobyta wiedza i doświadczenie w trakcie realizacji badań w zakresie metod sztucznej inteligencji umożliwiły realizację przez

Łukasiewicz-ITeE projektów w innych gałęziach przemysłu. Gromadzenie obszernych zbiorów danych z rzeczywistych procesów produkcyjnych zapewni podstawę do doskonalenia algorytmów wykrywania i klasyfikacji wad oraz opracowania modeli uczenia maszynowego wspierających optymalizację procesów produkcyjnych. Za perspektywiczny kierunek badań należy uznać wykorzystanie obrazów syntetycznych do doskonalenia i optymalizacji przemysłowych systemów wizyjnych. Istotnym obszarem dalszych prac jest również praktyczna implementacja systemu inspekcji w przemyśle spożywczym, stwarzająca nowe możliwości komercjalizacji wyników badań Instytutu.

Bibliografia

[1] Garbacz, P. (2024). Innowacyjne systemy kontroli jakości jako element koncepcji produkcji Zero Waste. W kierunku gospodarki o obiegu zamkniętym: możliwości i wyzwania, 127–134. Radom: Wydawnictwo Naukowe Sieć Badawcza Łukasiewicz – Instytut Technologii Eksploatacji.

[2] Rut, J.; Bartoszuk, M. (2018). Optimization of the Production Process Execution Through the Implementation of Manufacturing Execution System. Advances in Manufacturing Science and Technology, 42(1–4). DOI: 10.2478/amst-2018-0007

[3] Szmelter, A. (2013). Jidoka jako przykład kaizenowskich technik minimalizacji kosztów logistycznych przedsiębiorstw produkcji masowej. Zeszyty Naukowe Uniwersytetu Gdańskiego, 46, 149–158

[4] Villalba-Diez, J.; Gutierrez, M.; Martin, M. G.; Sterkenburgh, T.; Losada, J. C.; Benito, R. M. (2021). Quantum JIDOKA. Integration of Quantum Simulation on a CNC Machine for In–Process Control Visualization. Sensors, 21(15), 5031. DOI: https://doi.org/10.3390/s21155031.

[5] Rosak-Szyrocka, J.; Krynke, M.; Knop, K. (2017). Doskonalenie przedsiębiorstw w aspekcie czystszej produkcji i zrównoważonego rozwoju. Częstochowa: Oficyna Wydawnicza Stowarzyszenia Menedżerów Jakości i Produkcji.

[6] Cutulenco, G.; Ciceri, M.; Biron, J. (2024). Predictive Quality: The Future of Quality in Manufacturing. Acerta, White paper. Pobrano z: https://acerta.ai/predictive-quality-whitepaper/ (data dostępu 13.11.2025).

[7] Lahmine, S.; Bennouna, F. (2025). Bridging Classical Quality Tools and Industry 4.0: A Data-Driven Framework for Intelligent Process Control. Journal of Machine Engineering, 25(3), 5–17.

[8] Tripathi, A.; Kaushal, I.; Revolti, A.; Benedetti, L.; Dallasega, P. (2025). Digital Twin Driven Quality Control in Smart Mobile Factories: A Framework in Precast Manufacturing. Procedia CIRP, 134, 801–806. DOI: https://doi.org/10.1016/j.procir.2025.02.194.

[9] Davison, P.; Fahim, M.; Woods, R.; Fishaber, S.; Heron, M.; McAteer, C. (2025). Predictive Quality of In-Fabrication Products in Smart Manufacturing. Proceedings of the 22nd International Conference on Informatics in Control, Automation and Robotics. DOI: 10.5220/0013855100003982.

[10] Lario, J.; Mateos, J.; Psarommatis, F.; Ortiz, A. (2025). Towards Zero Defect and Zero Waste Manufacturing by Implementing Non-Destructive Inspection Technologies. Journal of Manufacturing and Materials Processing, 9(2), 29. DOI: https://doi.org/10.3390/jmmp9020029.

[11] Sioma, A. (2023). Vision System in Product Quality Control Systems. Applied Sciences, 13(2), 751. DOI: https://doi.org/10.3390/app13020751

[12] Cognex (2026). Learn from Defects to Improve Processes. https://www.cognex.com/en/tools-and-resources/resource-center/how-ai-is-eliminating-packaging-defects-at-the-source. (data dostępu: 18.02.2026).
[13] PMR Market Experts (2022). Rynek dań gotowych w Polsce stabilny w trudnych czasach. Pobrano z: https://www.pmrmarketexperts.com/wiadomosci/rynek-dan-gotowych-w-polsce-stabilny-w-trudnych-czasach/. (data dostępu: 07.09.2026).
[14] Brierley, N.; Tippetts, T.; Cawley, P. (2014). Data Fusion for Automated Non-Destructive Inspection. Proceedings of the Royal Society A, 470(2167), 20140167. DOI: https://doi.org/10.1098/rspa.2014.0167.
[15] Nimmagadda, S.; Nimmagadda, S. L.; Mani, N. (2019). Design and Development of a Real Time Vision Enhancement System Using Image Fusion – an Algorithmic Approach. Procedia Computer Science, 159, 990–1000. DOI: 10.1016/j.procs.2019.09.266
[16] Singh, S.; Singh, H.; Bueno, G.; Deniz, O.; Singh, S.; Monga, H.; Hrisheekesha, P. N.; Pedroza, A. (2023). A Review of Image Fusion: Methods, Applications and Performance Metrics. Digital Signal Processing, 137, 104020. DOI: 10.1016/j.dsp.2023.104020
[17] Wang, L.; Du, P.; Jin, R. (2021). MOSS — Multi-Modal Best Subset Modeling in Smart Manufacturing. Sensors, 21(1), 243. DOI: 10.3390/s21010243
[18] Saleh, B. (2012). Introduction to Subsurface Imaging. Cambridge University Press. DOI: 10.1017/CBO9780511732577
[19] Bielecki, Z.; Mikołajczyk, J.; Wojtas, J. (2024). A Review of Thermal Detectors of THz Radiation Operated at Room Temperature. Sensors, 24(21), 6784. DOI: 10.3390/s24216784
[20] Nargard, J. (2005). Electromagnetic Spectrum. The Electronics Handbook, Second Edition. Red. J. C. Whitaker. Taylor & Francis, 2–11.
[21] Sankaran, S.; Ehsani, R. (2014). Introduction to the Electromagnetic Spectrum. Imaging with Electromagnetic Spectrum. Applications in Food and Agriculture, 1–15.
[22] Demant, C.; Streicher-Abel, B.; Waszkewitz, P. (1999). Industrial Image Processing. Visual Quality Control in Manufacturing. Springer.
[23] Drury, C. G.; Watson, J. (2002). Good Practices in Visual Inspection. The Human Factors in Aviation Maintenance – Phase Nine, Progress Report. FAA, 4–7.
[24] Herbeck, T. (2009). Understanding Optical Inspection. Quality Magazine. https://www.qualitymag.com/articles/86659-understanding-optical-inspection (data dostępu: 08.09.2026).
[25] Zwinkels, J. (2015). Light, Electromagnetic Spectrum. W: Encyclopedia of Color Science and Technology. Red. R. Luo. Springer, Berlin, Heidelberg. DOI: 10.1007/978-3-642-27851-8_204-1.
[26] Buckner, B. D. (2002). Dissertation: Deep Ultraviolet Surface Inspection with Photoemission Enhancement. Arizona State University.
[27] Kobayashi, C.; Nishiwaki, T.; Tanabe, T.; Oohashi, T.; Hamasaki, H.; Hikishima, S.; Tanaka, A.; Arita, K.; Fujii, S.; Daisuke, S.; Kidokoro, T. (2024). Non-destructive testing

of reinforced concrete structures using sub-terahertz reflected waves. Developments in the Built Environment, 18, 100423. DOI: 10.1016/j.dibe.2024.100423.
[28] Rogalski, A.; Chrzanowski, K. (2014). Infrared Devices and Techniques (Revision). Metrology and Measurement Systems, XXI(4), 565–618. DOI: 10.2478/mms-2014-0057
[29] Mantsch, H. H.; Naumann, D. (2010). Terahertz spectroscopy: The renaissance of far infrared spectroscopy. Journal of Molecular Structure, 964(1–3), 1–4. DOI: 10.1016/j.molstruc.2009.12.022.
[30] Janóczki, M.; Becker, K.; Kos, J.; Jakab, L.; Gróf, R.; Takács, T. (2013). Automatic Optical Inspection of Soldering. Materials Science – Advanced Topics. InTech. DOI: 10.5772/51699.
[31] Wojnar, L. (2005). Digital Images and the Possibility of Their Computer Analysis. Micro-Structure Analysis of Plant Tissues, 71–116.
[32] Ursani, A. A. (2010). Multilevel Fusion for Classification of Very High Resolution Remote Sensing. https://tel.archives-ouvertes.fr/tel-00922645/document (data dostępu: 08.09.2026).
[33] Lapray, P.-J.; Wang, X.; Thomas, J.-B.; Gouton, P. (2014). Multispectral Filter Arrays: Recent Advances and Practical Implementation. Sensors, 14, 21626–21659. DOI: 10.3390/s141121626.
[34] Valme, D.; Rassõlkin, A.; Liyanage, D. C. (2025). From ADAS to Material-Informed Inspection: Review of Hyperspectral Imaging Applications on Mobile Ground Robots. Sensors, 25, 2346. DOI: 10.3390/s25082346.
[35] Mukhtar, S.; Arbabi, A.; Viegas, J. (2025). Advances in Spectral Imaging: A Review of Techniques and Technologies. IEEE Access, 13, 35848–35902. DOI: 10.1109/ACCESS.2025.3544476.
[36] Cheng, Y.; Deng, Y.; Cao, J.; Xiong, X.; Bai, L.; Li, Z. (2013). Multi-Wave and Hybrid Imaging Techniques: A New Direction for Nondestructive Testing and Structural Health Monitoring. Sensors, 13, 16146–16190. DOI: 10.3390/s131216146.
[37] Jing, H. (2003). Laser Range Imaging for On-Line Mapping of 3D Images to Pseudo-X-Ray Images for Poultry Bone Fragment Detection. Ph.D. Thesis, University of Maryland, College Park, MD, USA.
[38] Gros, X. E. (2001). Pixel Level NDT Data Fusion. In Applications of NDT Data Fusion. Springer, Boston, MA. DOI: 10.1007/978-1-4615-1411-4_3.
[39] Samimi, M.; Saadabadi, M.; Hosseinlaghab, H. (2024). Combined Use of Acoustic Measurement Techniques with X-ray Imaging for Real-Time Observation of Laser-Based Manufacturing. Metrology, 4, 181–204. DOI: 10.3390/metrology4020012.
[40] Wang, W.; Li, C. (2015). A Multimodal Machine Vision System for Quality Inspection of Onions. Journal of Food Engineering, 166, 291–301. DOI: 10.1016/j.jfoodeng.2015.06.027.
[41] Cornelis, B.; Yang, Y.; Vogelstein, J. T.; Dooms, A.; Daubechies, I.; Dunson, D. (2013). Bayesian Crack Detection in Ultra High Resolution Multimodal Images of Paintings. 18th

International Conference on Digital Signal Processing (DSP 2013), Fira. DOI: 10.48550/arXiv.1304.5894.
[42] Grenier, M.; Ibarra-Castanedo, C.; Maldague, X. (2011). Development of a Hybrid Non-Destructive Inspection System Combining Induction Thermography and Eddy Current Techniques. 10th International Conference on Quantitative InfraRed Thermography (QIRT 2010), Quebec, Canada, 24–29 Jun 2010.
[43] De, S.; Gupta, K.; Stanley, R. J.; Zoughi, R.; Doering, K.; Van Aken, D. (2012). A Comprehensive Structural Analysis Process for Failure Assessment in Aircraft Lap-Joint Mimics Using Intramodal Fusion of Eddy Current Data. Pages 146–170. DOI: 10.1080/09349847.2012.660242.
[44] Chen, Y.; Gao, Y.; Xu, K.; Yu, Z.; Xie, J.; Wang, C.; Zhu, F. (2025). A High-Accuracy and Robust Defect Detection Method for Electronic Packaging Based on Infrared–Visible Image Fusion. Optics & Laser Technology, 192 (Part E), 114038. DOI: 10.1016/j.optlastec.2025.114038.
[45] Jansen, H.; Platenkamp, D.; Hwang, J. (2024). Hybrid Inspection Method Using Three Dimensional Scanning, Lock-in Thermography and Laser Shearography. 20th World Conference on Non-Destructive Testing (WCNDT 2024), 27–31 May 2024, Incheon, South Korea. e-Journal of Nondestructive Testing, 29(6). DOI: 10.58286/29892.
[46] West, P. (2018). Optics for Machine Vision Practitioners. Automated Vision Systems. https://www.autovis.com/images/pdf/resources/optics-for-machine-vision-practitioners.pdf (data dostępu: 08.09.2026).
[47] Daniels, A. (2018). Field Guide to Infrared Optics, Materials, and Radiometry. DOI: 10.1117/3.2315931.
[48] Tabaka, P. (2007). Klasyfikacja odbicia światła od materiałów stosowanych na odbłyśniki. Seminarium Polsko-Ukraińskie Problemy Elektroenergetyki, Łódź, 11–12 czerwca 2007, 253–256.
[49] Tanner, D. B. (2019). Optical Effects in Solids. Cambridge University Press.
[50] Øgendal, L. (2016). Light Scattering: A Brief Introduction. University of Copenhagen, Copenhagen, Denmark, 3–4.
[51] Ticconi, F.; Pulvirenti, L.; Pierdicca, N. (2011). Models for Scattering from Rough Surfaces. Electromagnetic Waves, InTech, 203–226.
[52] Hsien-Che, L. (2005). Introduction to Color Imaging Science. Cambridge University Press. 150 - 158. DOI: 10.1017/CBO9780511614392.009
[53] Jaglarz, J.; Kapłonek, W.; Lipiński, W.; Pawełczak, M.; Synak, R. (2012). Badania porównawcze parametrów powierzchni gładkich. Elektronika, 92–99.
[54] Lilienfeld, P. (1986). Optical Detection of Particle Contamination on Surfaces: A Review. Aerosol Science and Technology, 5(2), 145–165. DOI: 10.1080/02786828608959085.
[55] Kim, J. H.; Ehrman, S. H.; Mulholland, G. W.; Germer, T. A. (2002). Polarized Light Scattering by Dielectric and Metallic Spheres on Silicon Wafers. Applied Optics, 41(25).
[56] Saleh, B. E.; Teich, M. C. (1991). Photons and Atoms. Fundamentals of Photonics, 423–457.

[57] O'Shea, C.; Holmes, A.; Winter, J.; Ou, X.; Dong, R.; He, S.; Kirchhof, P.; Fabritz, L.; Rajpoot, K.; Pavlovic, D. (2019). Cardiac Optogenetics and Optical Mapping – Overcoming Spectral Congestion in All-Optical Cardiac Electrophysiology. Frontiers in Physiology, 10.
[58] Hirose, A.; Lonngren, K. E. (2010). Fundamentals of Wave Phenomena, wyd. 2. Scitech Publishing Inc., Raleigh.
[59] Paquin, R. A. (1995). Properties of Metals. Handbook of Optics, Optical Society of America.
[60] Fox, M. (2010). Optical Properties of Solids. Oxford University Press.
[61] Dresselhaus, M. S. Optical Properties of Solids. W: Solid State Physics, 15-26.
[62] National Research Council (2010). Seeing Photons: Progress and Limits of Visible and Infrared Sensor Arrays. The National Academies Press, Washington, DC, 23–59. DOI: 10.17226/12896.
[63] Omelic, M.; Hrman, D. (2006). Measurements of UV Radiation During NDT Inspection. 9th European Conference on NDT, Proceedings BB 103-CD. Berlin: German Society for Non-Destructive Testing.
[64] ICNIRP (2004). ICNIRP Guidelines on Limits of Exposure to Ultraviolet Radiation of Wavelengths Between 180 nm and 400 nm (Incoherent Optical Radiation). Health Physics, 87(2), 171–186.
[65] Cao, F.; Liu, Y.; Liu, M.; Han, Z.; Xu, X.; Fan, Q.; Sun, B. (2024). Wide Bandgap Semiconductors for Ultraviolet Photodetectors: Approaches, Applications, and Prospects. Research, 7, 0385. DOI: 10.34133/research.0385.
[66] JLI Vision (2026). UV Light Proves Efficient for Detecting Oil Droplets. https://www.jlivision.com (data dostępu: 08.09.2026).
[67] Richards, A.; Oculus Photonics Partner (2010). Reflected Ultraviolet Imaging for Forensics Applications. Santa Barbara, 181–198.
[68] Hornberg, A. (2017). Handbook of Machine and Computer Vision: The Guide for Developers and Users. Wiley-VCH. DOI: 10.1002/9783527413409.
[69] Santos, E. R.; Tavares, V. M.; Duarte, A. C.; Furuya, H. A. (2021). Temperature Analysis of Driver and Optical Behavior of LED Lamps. Revista Brasileira de Aplicações de Vácuo, 40.
[70] Schnick, J. W. (2008). Calculus-Based Physics II. CreateSpace Independent Publishing Platform.
[71] Palus, H. (2006). Wybrane zagadnienia przetwarzania obrazów barwnych. Zeszyty Naukowe Politechniki Śląskiej, Automatyka, 147.
[72] Martin, D. (2013). A Practical Guide to Machine Vision Lighting. Advanced Illumination. www.advancedillumination.com/2018/10 (data dostępu: 08.09.2026).
[73] Zuech, N. (2000). Understanding and Applying Machine Vision, Revised and Expanded (2nd ed.). CRC Press. DOI: 10.1201/b16927.

[74] Losson, O.; Macaire, L.; Yang, Y. (2010). Comparison of Color Demosaicing Methods. Advances in Imaging and Electron Physics, 162, 173–265. DOI: 10.1016/S1076-5670(10)62005-8.
[75] Prayagi, P.; Wang, Y.; Shibui, S. (2026). Color Imaging in Machine Vision Cameras. JAI. www.jai.com (data dostępu: 08.09.2026).
[76] de Gioia, F.; Fanucci, L. (2021). Data-Driven Convolutional Model for Digital Color Image Demosaicing. Applied Sciences, 11, 9975. DOI: 10.3390/app11219975.
[77] Jiang, Z.; Yu, X.; Hao, Y. (2017). Design and Fabrication of a Ratiometric Planar Optode for Simultaneous Imaging of pH and Oxygen. Sensors, 17(6), 1316. DOI: 10.3390/s17061316.
[78] OMRON Automation (2011). Eight Tips for Optimal Machine Vision Lighting. Automate.org. www.automate.org (data dostępu: 08.09.2026).
[79] Zbrowski, A.; Giesko, T. (2008). Automatyzacja kontroli jakości wyrobów w linii technologicznej wytwarzania wałeczków łożysk tocznych. Technologia i Automatyzacja Montażu, 2, 36–40.
[80] Garbacz, P.; Giesko, T. (2016). Multi-Camera Vision System for the Inspection of Metal Shafts. Advances in Intelligent Systems and Computing, Challenges in Automation, Robotics and Measurement Techniques, 440, 743–752.
[81] Garbacz, P.; Mrozek, M. (2019). Inspection of Tableware Glass Products with Use of Structural Backlight. Journal of Machine Construction and Maintenance, 4, 49–54.
[82] Garbacz, P.; Czajka, P. (2014). Application of Optical Inspection Method for Testing the Correctness of Ball Bearings Assembly. Solid State Phenomena, 223, 264–271.
[83] International Electrotechnical Commission (2004). IEC 61920: Infrared Free Air Applications (Edition 2.0).
[84] Livada, Č.; Glavaš, H.; Baumgartner, A.; Jukić, D. The Dangers of Analyzing Thermographic Radiometric Data as Images. *J. Imaging* **2023**, *9*, 143. https://doi.org/10.3390/jimaging9070143.
[85] Castanedo, I. (2005). Doctoral Dissertation: Quantitative Subsurface Defect Evaluation by Pulsed Phase Thermography – Depth Retrieval with the Phase. Université Laval, Faculty of Graduate Studies.
[86] Notesco, G.; Ogen, Y.; Ben-Dor, E. (2016). Integration of Hyperspectral Shortwave and Longwave Infrared Remote-Sensing Data for Mineral Mapping of Makhtesh Ramon in Israel. Remote Sensing, 8, 318. DOI: 10.3390/rs8040318.
[87] Bennett, T. (2015). Photogrammetry and Transmitted Infrared Imaging to Document the Support of a 19th c. British Landscape Painting. COSCH e-Bulletin, 2.
[88] Obrutsky, A.; Acosta, D. (2004). Reflectography, a NDT Method for Images Diagnosis. In: Proceedings of the 16th World Conference on NDT.
[89] Gade, R.; Moeslund, T. B. (2014). Thermal Cameras and Applications: A Survey. Machine Vision and Applications, 25(1), 245–262. DOI: 10.1007/s00138-013-0570-5.
[90] Cengel, Y. A. (2002). Heat Transfer: A Practical Approach, 2nd ed. McGraw-Hill.

[91] Micro-Epsilon (rok). Basics of Non-Contact Temperature Measurement. Online: http://www.micro-epsilon.com (data dostępu: 08.09.2026).
[92] Vollmer, M.; Möllmann, K. P. (2010). Infrared Thermal Imaging: Fundamentals, Research and Applications. Wiley-VCH.
[93] Usamentiaga, R.; Venegas, P.; Guerediaga, J.; Vega, L.; Molleda, J.; Bulnes, F. G. (2014). Infrared Thermography for Temperature Measurement and Non-Destructive Testing. Sensors, 14, 12305–12348. DOI: 10.3390/s140712305.
[94] Melis, M. T.; Da Pelo, S.; Erbì, I.; Loche, M.; Deiana, G.; Demurtas, V.; Meloni, M. A.; Dessì, F.; Funedda, A.; Scaioni, M.; et al. (2020). Thermal Remote Sensing from UAVs: A Review on Methods in Coastal Cliffs Prone to Landslides. Remote Sensing, 12, 1971. https://doi.org/10.3390/rs12121971.
[95] Hooper, P. A. (2018). Melt Pool Temperature and Cooling Rates in Laser Powder Bed Fusion. Additive Manufacturing, 22, 548–559. DOI: 10.1016/j.addma.2018.05.032.
[96] Rogalski, A.; Chrzanowski, K. (2002). Infrared Devices and Techniques. Opto-Electronics Review, 10(2), 111–136.
[97] Firago, V.; Wójcik, W. (2015). High-Temperature Three-Colour Thermal Imager. Przegląd Elektrotechniczny, 208–214. DOI: 10.15199/48.2015.02.47.
[98] OSRAM (2016). High Power Emitters for Illumination Applications. Application Note AN095.
[99] Siesler, H. W.; Ozaki, Y.; Kawata, S.; Heise, M. H. (2006). Near-Infrared Spectroscopy: Principles, Instruments, Applications.
[100] Microsensor Technology LLC (2018). Near and Middle Infrared Optoelectronics: 1000–5000 nm. Datasheet, Rev. 280518. Online: http://lmsnt.com/datasheets.
[101] Das, N. C. (2010). Infrared Light Emitting Device with Two-Color Emission. Solid-State Electronics, 54(11), 1381–1383. DOI: 10.1016/j.sse.2010.06.007.
[102] Marin, N.; Buszka, J. (2013). Alternate Light Source Imaging: Forensic Photography Techniques. Routledge, New York. DOI: 10.4324/9781315722160.
[103] Hulewicz, A. (2015). Badania porównawcze wybranych źródeł światła. Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej, 4, 63–66.
[104] Minkina, W.; Dudzik, S. (2009). Infrared Thermography: Errors and Uncertainties. Wiley.
[105] Fidali, M. (2013). Metodyka termograficznej diagnostyki obiektów technicznych. Wydawnictwo Naukowe Instytutu Technologii Eksploatacji – PIB.
[106] Ibarra-Castanedo, C.; Genest, M.; Piau, J.-M.; Guibert, S.; Bendada, A.; Maldague, X. P. V. (2007). Active Infrared Thermography Techniques for the Nondestructive Testing of Materials. Ultrasonic and Advanced Methods for Nondestructive Testing and Material Characterization, 325–348. DOI: 10.1142/9789812770943_0014.
[107] Kwak, D.-H.; Yun, H.-W.; Lee, J.-H.; Kim, Y.-D.; Choi, D.-H. (2024). Sub-Terahertz Imaging-Based Real-Time Non-Destructive Inspection System for Estimating Water Activity and Foreign Matter Depth in Seaweed. Sensors, 24, 7599. DOI: 10.3390/s24237599.

[108] Giesko, T.; Mazurkiewicz, A. (2017). Optomechatronic Technologies Applied in Innovative Industry. Problemy Eksploatacji, 105, 25–34.
[109] Mittelman, D. M.; Gupta, M.; Neelamani, R.; Baraniuk, R. G.; Rudd, J. V.; Koch, M. (1999). Recent Advances in Terahertz Imaging. Applied Physics B: Lasers and Optics, 68, 1085–1094.
[110] Pogson, E. M. (2012). Terahertz Applications in Medicine, the Environment and Optics. Dissertation, Institute for Superconducting and Electronic Materials, Centre for Medical Radiation Physics, University of Wollongong
[111] Garbacz, P. (2017). Terehertz Imaging – Principles, Techniques, Benefits and Limitations. Problemy Eksploatacji.
[112] Cubillos, J. L.; Del Rio, C. (2010). Resolution Capabilities of Future THz Cameras. Radioengineering, 20(2), 373–379.
[113] Cooke, M. (2007). Filling the THz Gap with New Applications. Semiconductor Today, Juno Publishing and Media Solutions Ltd, 2.
[114] Czajka, P. (2012). Hybrydowe systemy automatycznej kontroli jakości w procesach produkcji. Instytut Technologii Eksploatacji – PIB, Radom.
[115] Jiang, D.; Zhuang, D.; Huang, Y.; Fu, J. (2011). Survey of Multispectral Image Fusion Techniques in Remote Sensing Applications. W: Image Fusion and Its Applications. InTech. DOI: 10.5772/10548.
[116] Mitchell, H. B. (2007). Multi-Sensor Data Fusion. Springer.
[117] Lahat, D.; Adali, T.; Jutten, C. (2015). Multimodal Data Fusion: An Overview of Methods, Challenges and Prospects. Proceedings of the IEEE, 103(9), 1449–1477. DOI: 10.1109/JPROC.2015.2460697.
[118] Han, M.; Yu, K.; Qiu, J.; Li, H.; Wu, D.; Rao, Y.; Yang, Y.; Xing, L.; Bai, H.; Zhou, C. (2023). Boosting Target-Level Infrared and Visible Image Fusion with Regional. Information Fusion, 92, 268–288.
[119] Ma, J.; Ma, Y.; Li, C. (2012). Infrared and Visible Image Fusion Methods and Applications. Information Fusion, 13, 48–59.
[120] Cognex (2025). How AI Is Eliminating Packaging Defects at the Source. https://www.cognex.com/. (data dostępu: 08.09.2026)
[121] Banús, N.; Boada, I.; Xiberta, P.; Toldrà, P.; Bustins, N. (2021). Deep Learning for the Quality Control of Thermoforming Food Packages. Scientific Reports, 11, 21887. DOI: 10.1038/s41598-021-01254-x.
[122] National Instruments (2026). Inspecting Transparent Materials for Material Defects. Pobrano z: https://www.ni.com (data dostępu: 08.09.2026).
[123] Hogan, H. (2017). Getting the Picture on Quality Control. Pobrano z: https://www.photonics.com/ (data dostępu: 08.09.2026).
[124] Zanon Diaz, J.; Corcoran, P. (2024). Surface Seal Image Dataset of Sterile Barrier Packaging. Data in Brief, 57, 110996. DOI: 10.1016/j.dib.2024.110996.

[125] Barnes, M.; Dudbridge, M.; Duckett, T. (2012). Polarised Light Stress Analysis and Laser Scatter Imaging for Non-Contact Inspection of Heat Seals in Food Trays. University of Lincoln, Journal Contribution. HDL: https://hdl.handle.net/10779/lincoln.24401185.v4.
[126] Guillot, V. (2023). Infrared Thermography for Seal Defects Detection on Packaged Products: Unbalanced Machine Learning Classification with Iterative Digital Image Restoration. ELCVIA, 22, 35–51. DOI: 10.5565/rev/elcvia.1567.
[127] Sightech Vision (2021). TheSealCheck: Seal Inspection Using Thermal Imaging Technology. Pobrano z: https://thesealcheck.com/ (data dostępu: 08.09.2026).
[128] Acuros. SWIR Camera Applications Note: Machine Vision Inspection Through Opaque Plastic Packaging. https://www.swirvisionsystems.com/ (data dostępu: 08.09.2026).
[129] Hao, Z.; Chen, Y.; Yu, Z.; Qian, Y.; Zhao, L. (2025). Thermal Imaging-Based Defect Detection Method for Aluminum Foil Sealing Using EAC-Net. Applied Sciences, 15, 9964. DOI: 10.3390/app15189964.
[130] D'huys, K.; Saeys, W.; De Ketelaere, B. (2016). Active Infrared Thermography for Seal Contamination Detection in Heat-Sealed Food Packaging. J. Imaging, 2, 33. DOI: 10.3390/jimaging2040033.
[131] Wang, L.; Leng, Z.; Jiang, C.; Hua, R. (2026). Thermal Imaging for Sealing Defect Detection in Pharmaceutical Bags Using a Temporal Fusion Network. PLoS One, 21(3), e0343395. DOI: 10.1371/journal.pone.0343395.
[132] Dechow, D. L.; Nagi, N. (2022). Advanced Imaging and Deep Learning Technologies Execute Critical Packaging Inspection. Quality Magazine, 61(3).
[133] Engilico (2024). HyperScope: Hyperspectral Seal Inspection of Plastic and Paper-Based Rigid Packaging. https://www.engilico.com/ (data dostępu: 08.09.2026).
[134] Benouis, M.; Medus, L. D.; Saban, M.; Ghemougui, A.; Rosado-Muñoz, A. (2021). Food Tray Sealing Fault Detection in Multi-Spectral Images Using Data Fusion and Deep Learning Techniques. J. Imaging, 7, 186. https://doi.org/10.3390/jimaging7090186.
[135] Linowska, B.; Garbacz, P. (2023). Hyperspectral Imaging System for Food Safety Inspection. Automation 2023: Key Challenges in Automation, Robotics and Measurement Techniques. AUTOMATION 2023. Lecture Notes in Networks and Systems, 630.
[136] Taheri, H.; Riggs, P.; Widem, N.; Taheri, M. (2023). Heat-Sealing Integrity Assessment Through Nondestructive Evaluation Techniques. Packaging Technology and Science, 36(2), 67–80. https://doi.org/10.1002/pts.2696.
[137] Sites, P. W.; Roche, B. A.; Jones, C. F.; Griner, J. C. (1995). Package Seal Inspection System. Patent US5515159A.
[138] Ignatowicz, S. (2005). Method and Apparatus for Monitoring and Detecting Defects in Plastic Package Sealing. Patent US7434986B2.
[139] MoviTherm (2022). Thermal Seal Inspection for Plastic Joining & Welding. https://movitherm.com/ (data dostępu: 08.09.2026).
[140] Specim (2025). Inspecting Heat-Sealed Packages. https://www.specim.com (data dostępu: 08.09.2026).

[141] Inspectra (2024). Machine Vision Solutions for the Food Industry. https://inspectra-vision.com (data dostępu: 08.09.2026).
[142] Al-Habaibeh, A.; Shi, F.; Brown, N.; Kerr, D.; Jackson, M.; Parkin, R. M. (2004). A Novel Approach for Quality Control System Using Sensor Fusion of Infrared and Visual Image Processing for Laser Sealing of Food Containers. Measurement Science and Technology, 15(10).
[143] Lun, Z.; Wu, X.; Dong, J.; Wu, B. (2025). Deep Learning-Enhanced Spectroscopic Technologies for Food Quality Assessment: Convergence and Emerging Frontiers. Foods, 14, 2350. https://doi.org/10.3390/foods14132350.
[144] Ministerstwo Rozwoju i Technologii (2023). Krajowe Inteligentne Specjalizacje – Szczegółowy Opis. www.gov.pl (data dostępu: 08.09.2026).
[145] Ilhan, I.; Turan, D.; Gibson, I.; ten Klooster, R. (2021). Understanding the Factors Affecting the Seal Integrity in Heat-Sealed Flexible Food Packages: A Review. Packaging Technology and Science, 34, 321–337. https://doi.org/10.1002/pts.2564.
[146] Giesko, T. (2013). Metodyka projektowania i implementacji innowacyjnych systemów optomechatronicznych., Biblioteka Problemów Eksploatacji – Studia i Rozprawy.
[147] Frey, D.; Herder, P.; Wijnia, Y.; Subrahmanian, E.; Katsikopoulos, K.; Clausing, D. (2009). The Pugh Controlled Convergence Method: Model-Based Evaluation and Implications for Design Theory. Research in Engineering Design, 20, 41–58.
[148] Burge, S. (2009). The Systems Engineering Tool Box. www.burgehugheswalsh.co.uk (data dostępu: 08.09.2026).
[149] Zbrowski, A. (2016). Metodyka badań prototypów i jednostkowych urządzeń technicznych. Wydawnictwo Naukowe Instytutu Technologii Eksploatacji – PIB.
[150] Huang, K.; Wang, C.; Wang, S.; Liu, R.; Chen, G.; Li, X. (2021). An Efficient, Platform-Independent Map Rendering Framework for Mobile Augmented Reality. ISPRS International Journal of Geo-Information, 10, 593. https://doi.org/10.3390/ijgi10090593.
[151] Marshal, A. D.; Martin, R. R. (1993). Computer Vision, Models and Inspections. Singapore: World Scientific Publishing Co. Pte. Ltd.
[152] Steger, C.; Ulrich, M. (2021). A Camera Model for Line-Scan Cameras with Telecentric Lenses. International Journal of Computer Vision, 129, 80–99. https://doi.org/10.1007/s11263-020-01358-3.
[153] Bräuer-Burchardt, C.; Ramm, R.; Kühmstedt, P.; Notni, G. (2022). The Duality of Ray-Based and Pinhole-Camera Modeling and 3D Measurement Improvements Using the Ray-Based Model. Sensors, 22, 7540. https://doi.org/10.3390/s22197540.
[154] Reiner, J. (2013). Identyfikacja i modelowanie optyczne systemów wizyjnej kontroli jakości wytwarzania. Wrocław: Oficyna Wydawnicza Politechniki Wrocławskiej.
[155] Kumar, D. P.; Kannan, K. (2010). A Roadmap for Designing an Automated Visual Inspection System. International Journal of Computer Applications, 1(19), 34–37.
[156] Abbas, H. Kh.; Mohamad, H. J.; Al-Saleh, A. H.; Al-Zuky, A. A. (2019). Modelling Vision Angles of Optical Camera Zoom Using Image Processing Algorithm. IOP

Conference Series: Materials Science and Engineering, 571, 012117. https://doi.org/10.1088/1757-899X/571/1/012117.
[157] Cahyadi, W. A.; Chung, Y. H.; Ghassemlooy, Z.; Hassan, N. B. (2020). Optical Camera Communications: Principles, Modulations, Potential and Challenges. Electronics, 9, 1339. https://doi.org/10.3390/electronics9091339.
[158] Burke, M. W. (1996). Image Acquisition. W: Handbook of Machine Vision Engineering. Chapman & Hall.
[159] Imaging & Machine Vision Europe (2026). Advances in Algorithms. https://www.imveurope.com/feature/advances-algorithms (data dostępu: 14.03.2026).
[160] Keyence (2026). Concept of Minimum Detectable Object Size. https://www.keyence.com (data dostępu: 08.09.2026).
[161] Opto Engineering (2026). Optimizing System Resolution: A Practical Guide to Matching Lens and Sensor MTF. https://www.opto-e.com/ (data dostępu: 08.09.2026).
[162] Jamil, S. (2024). Review of Image Quality Assessment Methods for Compressed Images. Journal of Imaging, 10, 113. https://doi.org/10.3390/jimaging10050113.
[163] Fulir, J.; Jeziorski, N.; Bosnar, L.; Hagen, H.; Redenbach, C.; Herrfurth, T.; Trost, M.; Gischkat, T.; Gospodnetić, P. SYNOSIS: Image Synthesis Pipeline for Machine Vision in Metal Surface Inspection. Sensors 2025, 25, 6016. https://doi.org/10.3390/s25196016.
[164] Węgliński, T.; Fabijańska, A. (2013). Enhancement of Low-Dose CT Scans. Informatyka, Automatyka, Pomiary w Gospodarce i Ochronie Środowiska, 3(4), 7–9. https://doi.org/10.35784/iapgos.1469
[165] Nguyen, V.-H.; Pham, T.-N.; Huh, J.-H.; Choi, P.-J.; Kim, Y.-B.; Kwon, O.-H.; Kwon, K.-R. (2025). Efficient Synthetic Defect on 3D Object Reconstruction and Generation Pipeline for Digital Twins Smart Factory. Sensors, 25, 6908. https://doi.org/10.3390/s25226908.
[166] Basler (2015). How Do You Assess Image Quality? https://www.baslerweb.com (data dostępu: 08.09.2026).
[167] Pambrun, J.-F.; Noumeir, R. (2015). Limitations of the SSIM Quality Metric in the Context of Diagnostic Imaging. W: 2015 International Conference on Image Processing (ICIP). DOI: 10.1109/ICIP.2015.7351345.
[168] Basler AG. Basler Racer. User's Manual for GigE Vision Cameras. https://www.baslerweb.com (data dostępu: 08.09.2026).
[169] Schneider Kreuznach (2026). Emerald 2.2/50F Datasheet. https://schneiderkreuznach.com (data dostępu: 08.09.2026).
[170] Heugen, M. (2026). Triggering and Strobing Machine Vision Lighting. https://www.machine-vision-shop.com/ (data dostępu: 08.09.2026).
[171] IDS; Diezemann, D.; Gentele, M. (2016). IDS TechTip: Subsampling, Binning, or Scaler. https://www.ids-imaging.com (data dostępu: 08.09.2026).
[172] Ramírez-Hernández, L. R.; Rodríguez-Quiñonez, J. C.; Castro-Toscano, M. J.; et al. (2020). Improve Three-Dimensional Point Localization Accuracy in Stereo Vision

Systems Using a Novel Camera Calibration Method. International Journal of Advanced Robotic Systems, 17(1). https://doi.org/10.1177/1729881419896717
[173] Cao, Y.; Xu, B.; Ye, Z.; Yang, J.; Cao, Y.; Tisse, C.-L.; Xin, L. (2018). Depth and Thermal Sensor Fusion to Enhance 3D Thermographic Reconstruction. Optics Express, 26, 8179–8193. https://doi.org/10.1364/OE.26.008179
[174] Drap, P.; Lefèvre, J. (2016). An Exact Formula for Calculating Inverse Radial Lens Distortions. Sensors, 16, 807. https://doi.org/10.3390/s16060807.
[175] Zebra Technologies (2026). Dokumentacja Aurora Vision Studio. https://docs.adaptive-vision.com/current/studio/ (data dostępu: 08.09.2026).
[176] Garbacz, P. (2025). A Target-Oriented Image Fusion Method for Quality Inspection of Heat-Sealed Packages. W: Trajdos, P.; Burduk, R. (red.) Progress in Pattern Classification and Machine Learning. CORES 2025. Lecture Notes in Networks and Systems, 1557. Springer, Cham. https://doi.org/10.1007/978-3-032-01773-4_3.
[177] Pietrzkiewicz, P. (2019). Image Analysis Techniques for Industrial Inspection Systems. https://www.adaptive-vision.com/download/mvg.pdf (data dostępu: 08.09.2026).
[178] Zitová, B.; Flusser, J. (2003). Image Registration Methods: A Survey. Image and Vision Computing, 21(11), 977–1000. https://doi.org/10.1016/S0262-8856(03)00137-9.
[179] Luo, Y.; Wang, X.; Liao, Y.; Fu, Q.; Shu, C.; Wu, Y.; He, Y. (2023). A Review of Homography Estimation: Advances and Challenges. Electronics, 12, 4977. https://doi.org/10.3390/electronics12244977.
[180] Shahsavarani, S.; Lopez, F.; Ibarra-Castanedo, C.; Maldague, X. P. V. (2024). Robust Multi-Modal Image Registration for Image Fusion Enhancement in Infrastructure Inspection. Sensors, 24, 3994. https://doi.org/10.3390/s24123994.
[181] Pekat Vision (2024). Machine Vision in Quality Inspection: Traditional vs. Deep Learning Approaches. https://www.pekatvision.com (data dostępu: 08.09.2026).
[182] Cognex (2025). Rule-Based vs AI-Powered Machine Vision. https://www.cognex.com (data dostępu: 08.09.2026).
[183] He, K.; Zhang, Z.; Ren, S.; Sun, J. (2015). Deep Residual Learning for Image Recognition. https://arxiv.org/pdf/1512.03385 (data dostępu: 08.09.2026).
[184] Nigar, N.; Umar, M.; Shahzad, M. K.; Islam, S.; Abalo, D. (2022). A Deep Learning Approach Based on Explainable Artificial Intelligence for Skin Lesion Classification. IEEE Access, 10, 113715–113725. https://doi.org/10.1109/ACCESS.2022.3217217.
[185] Pérez-Aguilar, D.; Risco-Ramos, R.; Casaverde-Pacherrez, L. (2021). Transfer Learning for Binary Classification of Thermal Images. Ingenius, 26, 71–86. https://doi.org/10.17163/ings.n26.2021.07.
[186] Liashchynskyi, N.; Liashchynskyi, P. (2019). Grid Search, Random Search, Genetic Algorithm: A Big. https://doi.org/10.48550/arXiv.1912.06059 (data dostępu: 08.09.2026).
[187] Ma, Y.; Yin, J.; Huang, F.; Li, Q. (2024). Surface Defect Inspection of Industrial Products with Object Detection Deep Networks: A Systematic Review. Artificial Intelligence Review, 57, 333. https://doi.org/10.1007/s10462-024-10956-3.

[188] Liu, G.; Yang, D.; Ye, J.; Lu, H.; Wang, Z.; Zhao, Y. (2025). A Real-Time Welding Defect Detection Framework Based on RT-DETR Deep Neural Network. Advanced Engineering Informatics, 65, 103318. https://doi.org/10.1016/j.aei.2025.103318.
[189] Mohammed, S. Y. (2025). Architecture Review: Two-Stage and One-Stage Object Detection. Franklin Open, 12, 100322. https://doi.org/10.1016/j.fraope.2025.100322.
[190] Mao, M.; Hong, M. (2025). YOLO Object Detection for Real-Time Fabric Defect Inspection in the Textile Industry: A Review of YOLOv1 to YOLOv11. Sensors, 25, 2270. https://doi.org/10.3390/s25072270.
[191] Tian, Y.; Ye, Q.; Doermann, D. (2025). YOLOv12: Attention-Centric Real-Time Object Detectors. arXiv preprint. https://doi.org/10.48550/arXiv.2502.12524 (data dostępu: 08.09.2026).
[192] Roboflow (2026). Roboflow Documentation. https://roboflow.com (data dostępu: 08.09.2026).
[193] Allgaier, J.; Pryss, R. (2024). Cross-Validation Visualized: A Narrative Guide to Advanced Methods. Machine Learning and Knowledge Extraction, 6, 1378–1388. https://doi.org/10.3390/make6020065.
[194] Ultralytics (2026). Ultralytics YOLO Documentation. https://docs.ultralytics.com (data dostępu: 08.09.2026).
[195] Czajka, P.; Mizak, W.; Mężyk, J. (2025). Urządzenie do kontroli saszetek zgrzewanych termicznie. Technologia i Automatyzacja Montażu, 128, 49–69.
[196] Tercan, H.; Meisen, T. (2022). Machine Learning and Deep Learning Based Predictive Quality in Manufacturing: A Systematic Review. Journal of Intelligent Manufacturing, 33, 1879–1905. https://doi.org/10.1007/s10845-022-01963-8.
[197] Garbacz, P.; Burghardt, A.; Czajka, P.; Mężyk, J.; Mizak, W. (2026). Predictive Modeling of Packaging Seal Strength: A Hybrid Vision and Process Data Approach for Non-Destructive Quality Assurance. Applied Sciences, 16, 923. https://doi.org/10.3390/app16020923.
[198] Barreira, E.; Almeida, R. M. S. F.; Simões, M. L. (2021). Emissivity of Building Materials for Infrared Measurements. Sensors, 21, 1961. https://doi.org/10.3390/s21061961.
[199] Seaborn (2026). Comparing Distributions. https://seaborn.pydata.org (data dostępu: 08.09.2026).
[200] Gregorutti, B.; Michel, B.; Saint-Pierre, P. (2017). Correlation and Variable Importance in Random Forests. Statistics and Computing, 27, 659–678. https://doi.org/10.1007/s11222-016-9646-1.
[201] Harrell, F. E. (2015). Regression Modeling Strategies. Springer Series in Statistics. https://doi.org/10.1007/978-3-319-19425-7.
[202] Othman, S.; Mavani, N. R.; Hussain, M. A.; Abd Rahman, N.; Mohd Ali, J. (2023). Artificial Intelligence-Based Techniques for Adulteration and Defect Detections in Food and Agricultural Industry: A Review. Journal of Agriculture and Food Research, 12, 100590. https://doi.org/10.1016/j.jafr.2023.100590.

[203] Varma, S.; Simon, R. (2006). Bias in Error Estimation When Using Cross-Validation for Model Selection. BMC Bioinformatics, 7, 91. https://doi.org/10.1186/1471-2105-7-91.
[204] Pamplona Berón, L. E.; De Simone, M. C.; de Falco, D.; Guida, D. (2026). Machine Learning-Based Classification of Vibration Patterns Under Multiple Excitation Scenarios for Structural Health Monitoring. Applied Sciences, 16, 2107. https://doi.org/10.3390/app16042107.
[205] Steyerberg, E. W.; Harrell, F. E. Jr.; Borsboom, G. J.; Eijkemans, M. J.; Vergouwe, Y.; Habbema, J. D. (2001). Internal Validation of Predictive Models: Efficiency of Some Procedures for Logistic Regression Analysis. Journal of Clinical Epidemiology, 54(8), 774–781. https://doi.org/10.1016/s0895-4356(01)00341-9.
[206] Raschka, S. (2020). Model Evaluation, Model Selection, and Algorithm Selection in Machine Learning. arXiv preprint. https://doi.org/10.48550/arXiv.1811.12808 (data dostępu: 08.09.2026).
[207] Lamidi, S.; Olalere, R.; Yekinni, A.; Adesina, K. (2024). Design of Experiments (DOE): Applications and Benefits in Quality Control and Assurance. In *Industrial Engineering and Management*. IntechOpen. https://doi.org/10.5772/intechopen.113987.
[208] Lanati, A.; Poli, C.; Imberti, M.; Menegon, A.; Grohovaz, F. (2015). A Design of Experiment Approach to Optimize an Image Analysis Protocol for Drug Screening. In Zazzu, V.; Ferraro, M.; Guarracino, M. (eds), Mathematical Models in Biology. Springer, Cham. https://doi.org/10.1007/978-3-319-23497-7_5.
[209] Muruganantham, C.; Jawahar, N.; Ramamoorthy, B.; Giridhar, D. (2009). Optimal Settings for Vision Camera Calibration. The International Journal of Advanced Manufacturing Technology, 42, 736–748. https://doi.org/10.1007/s00170-008-1634-y.
[210] Zorcolo, G.; Escobar-Palafox, R.; Gault, R.; Scott, R.; Ridgway, K. (2009). Study of Lighting Solutions in Machine Vision Applications for Automated Assembly. In *Trends in Aerospace Manufacturing 2009 International Conference*. https://doi.org/10.1088/1757-899X/26/1/012019.
[211] Złotoś, M. (2025). Wybrane Metody Planowania Eksperymentów w Badaniach Ekonomicznych. Katowice: Wydawnictwo Uniwersytetu Ekonomicznego w Katowicach.
[212] MiniTab (2026). What Is Randomization? https://support.minitab.com (data dostępu: 08.09.2026).
[213] Kopcek, M.; Skulavik, T.; Tanuska, P.; Mudroncik, D. (2014). Systematic Approach to Factory Acceptance Test Planning. In Klemeš, J. J.; Varbanov, P. S.; Liew, P. Y. (eds), *Computer Aided Chemical Engineering*, 33, 1597–1602. Elsevier. https://doi.org/10.1016/B978-0-444-63434-4.50053-5.
[214] Automated Vision Systems, Inc. (2026). The Vision System Acceptance Test: Defining Done. https://autovis.com (data dostępu: 08.09.2026).
[215] Vision & Control (2026). Clear Communication – Effective Image Processing to VDI 2632. https://www.vision-control.com (data dostępu: 08.09.2026).

[216] Aust, J.; Pons, D. (2022). Assessment of Aircraft Engine Blade Inspection Performance Using Attribute Agreement Analysis. Safety, 8, 23. https://doi.org/10.3390/safety8020023.

[217] Simion, C. (2016). Evaluation of an Attributive Measurement System in the Automotive Industry. IOP Conference Series: Materials Science and Engineering, 145(5), 052005. https://doi.org/10.1088/1757-899X/145/5/052005.

[218] Simion, C. (2019). Measurement System Analysis by Attribute: An Effective Tool to Ensure the Quality of the Visual Inspection Process Within an Organization. MATEC Web of Conferences, 290, 05004. https://doi.org/10.1051/matecconf/201929005004.